

多工况下滚动轴承早期故障检测与融合诊断关键技术研究



博士研究生学位论文答辩

答 辩 人：康玉祥
指导教师：陈果 教授
专 业：载运工具运用工程



智能诊断与专家系统

2023年12月



南京航空航天大学

Nanjing University of Aeronautics and Astronautics

目录

1

绪论

2

无故障样本的滚动轴承故障异常检测

3

含少量故障样本的滚动轴承故障诊断

4

低速转动状态下滚动轴承故障异常检测

5

基于振动和油液的滚动轴承故障智能融合诊断

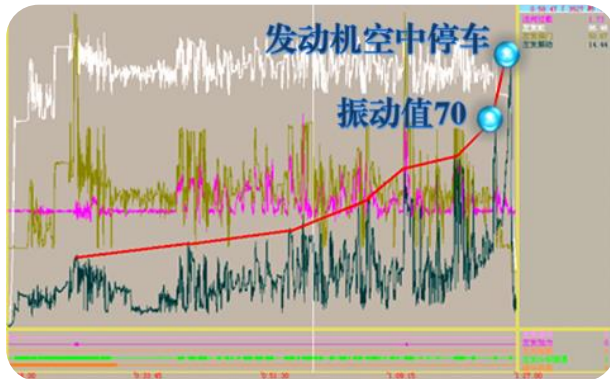
6

总结与展望


- **来源1：国家科技重大专项子专题——复杂服役环境下主轴承典型故障宏观动力学研究 (J2019-IV-0004-0071)**
- **来源2：国家自然科学基金项目(52272436)——基于深度异常检测和元学习的航空发动机主轴承早期故障预警与演化诊断**




阿勒-31F系列发动机五支点轴承失效，共发生29起发动机抱轴、断轴，造成歼10飞机2起严重飞行事故、1起飞机迫降



5号轴承严重磨损




低压涡轮轴折断



- 剥落
- 点蚀
- 磨损


阿勒-31F五支点主轴承失效模式

- ◆ xx-10系列主轴承失效三支点14起、四支点4起，导致空海军发生6起空中停车事故征候、1起空中振动超标，外场无管用监控手段；
- ◆ 近年来，我军接连发生多起轴承失效导致的空中停车事故征候；
- ◆ **可见对于航空发动机主轴承进行健康监测已经成为了一项迫在眉睫的工作。**



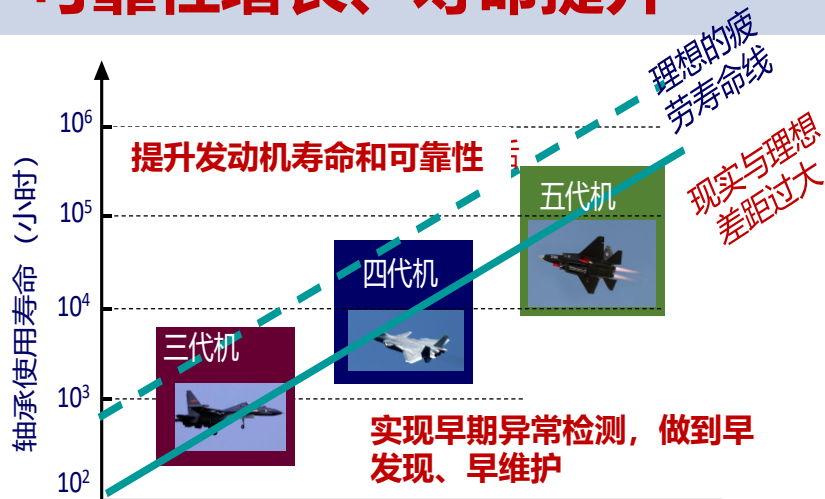
- ◆ 国家的科技重大专项中，涉及了关于主轴承攻关的项目，可见主轴承已经成为了制约我国航空发动机安全运行的关键、重要的部件。

◆ 早期失效占比大，是我国航空发动机发展瓶颈之一



◆ 典型故障样本匮乏，是制约主轴承高精度智能诊断的因素之一。

可靠性增长、寿命提升



1) 少故障样本下航空发动机主轴承故障难诊断的问题

当前基于深度学习的诊断方法假设正常和故障两种状态的样本数量相当，且所有的样本均进行了标注。然而，类似航空发动机这种不能“带病”运行的系统，其典型故障数据往往很难获取，甚至无法获取。使得这类方法的诊断精度不高。

2) 航空发动机低转速下滚动轴承故障难诊断的问题

由于传递路径的影响，使得所能监测到的故障冲击信号更加微弱。此外，低转速下很难或无法通过寻找特征频率的方法实现滚动轴承的诊断。鉴于此，对于低转速航空发动机滚动轴承而言，采用深度学习方法，实现对滚动轴承的故障监测，对于保障飞行安全，降低维修维护成本有重要的意义。

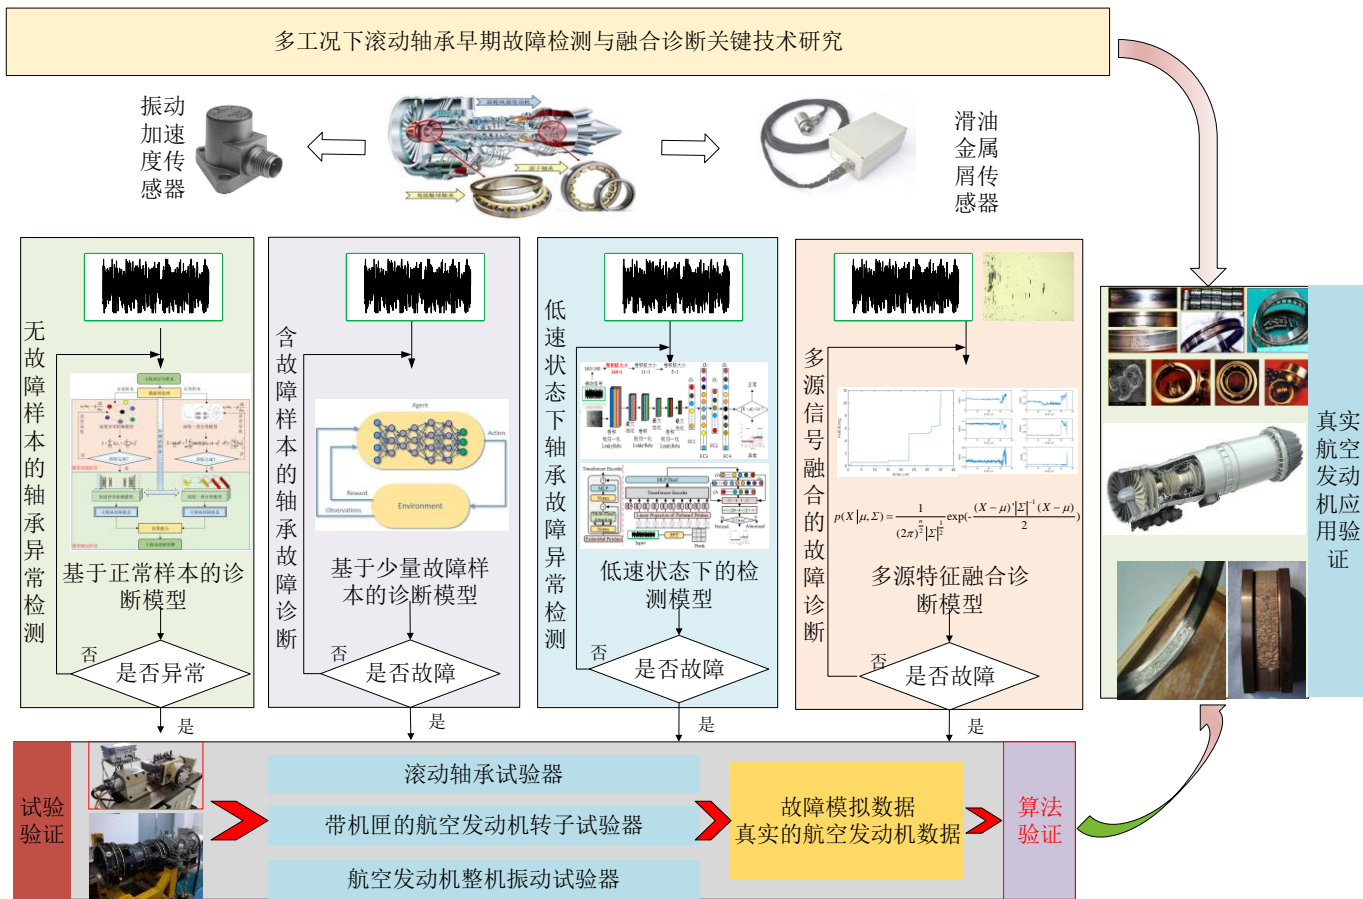
3) 无法有效利用多源数据实现在线诊断

当前，滚动轴承各种源数据通常是“各自为战”。一般而言，振动对于早期故障敏感，而油液分析数据对轴承晚期故障敏感。因此，仅仅依靠单一数据源实现的滚动轴承故障监测与诊断，无法很好的保证诊断的可靠性。

引入深度学习，开展多工况下滚动轴承早期故障检测与融合诊断关键技术研究，包括：无故障样本下滚动轴承故障异常检测方法的研究、少量不平衡数据样本下滚动轴承的故障诊断、低转速滚动轴承故障检测、以及振动和油液检测数据的智能融合诊断，以期实现多工况下的滚动轴承故障可靠诊断。

论文研究内容及安排

第一章



目录

1

绪论

2

无故障样本的滚动轴承故障异常检测

3

含少量故障样本的滚动轴承故障诊断

4

低速转动状态下滚动轴承故障异常检测


5

基于振动和油液的滚动轴承故障智能融合诊断

6

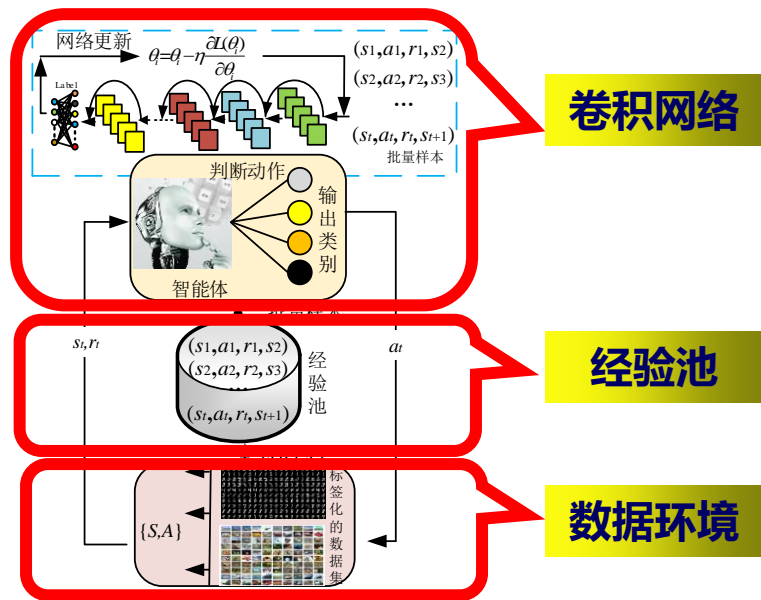
总结与展望

理论基础1——深度一类分类方法



仅利用正常数据进行训练。模型将正常样本神经网络映射后落入超球内部，异常样本神经网络映射后落入超球外部，从而完成检测。

理论基础2——分类马尔可夫决策

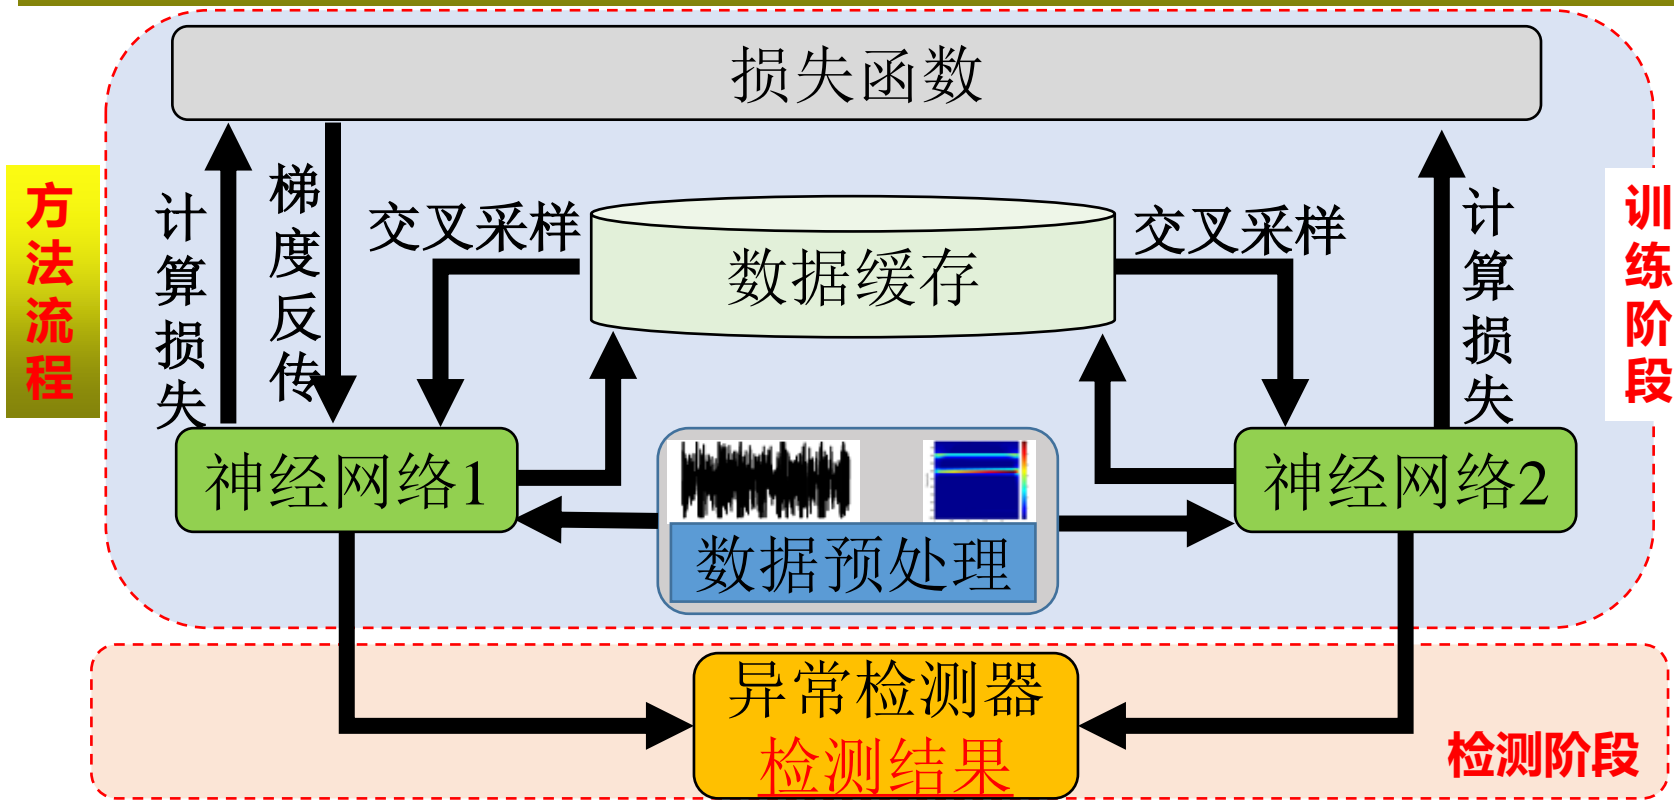


通过深度强化学习寻找最优的样本至故障类别的映射策略 $\pi(\theta)$

无故障样本的滚动轴承故障异常检测

第二章

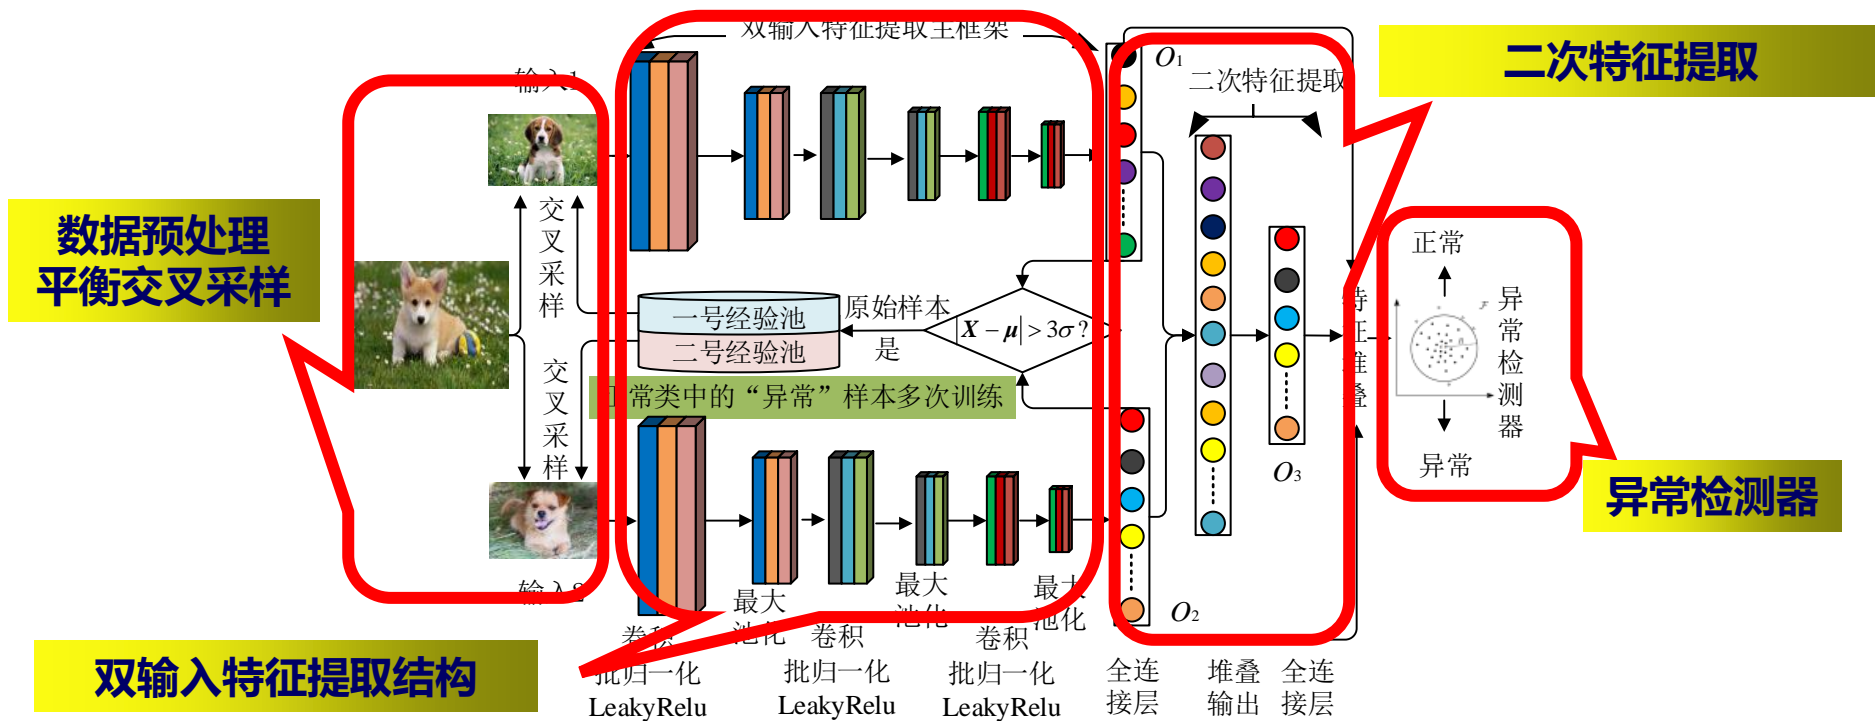
研究目的：提出了融合深度强化学习的双输入异常检测方法，解决实际工程中因无故障类样本而导致的诊断精度不高的问题。



无故障样本的滚动轴承故障异常检测

第二章

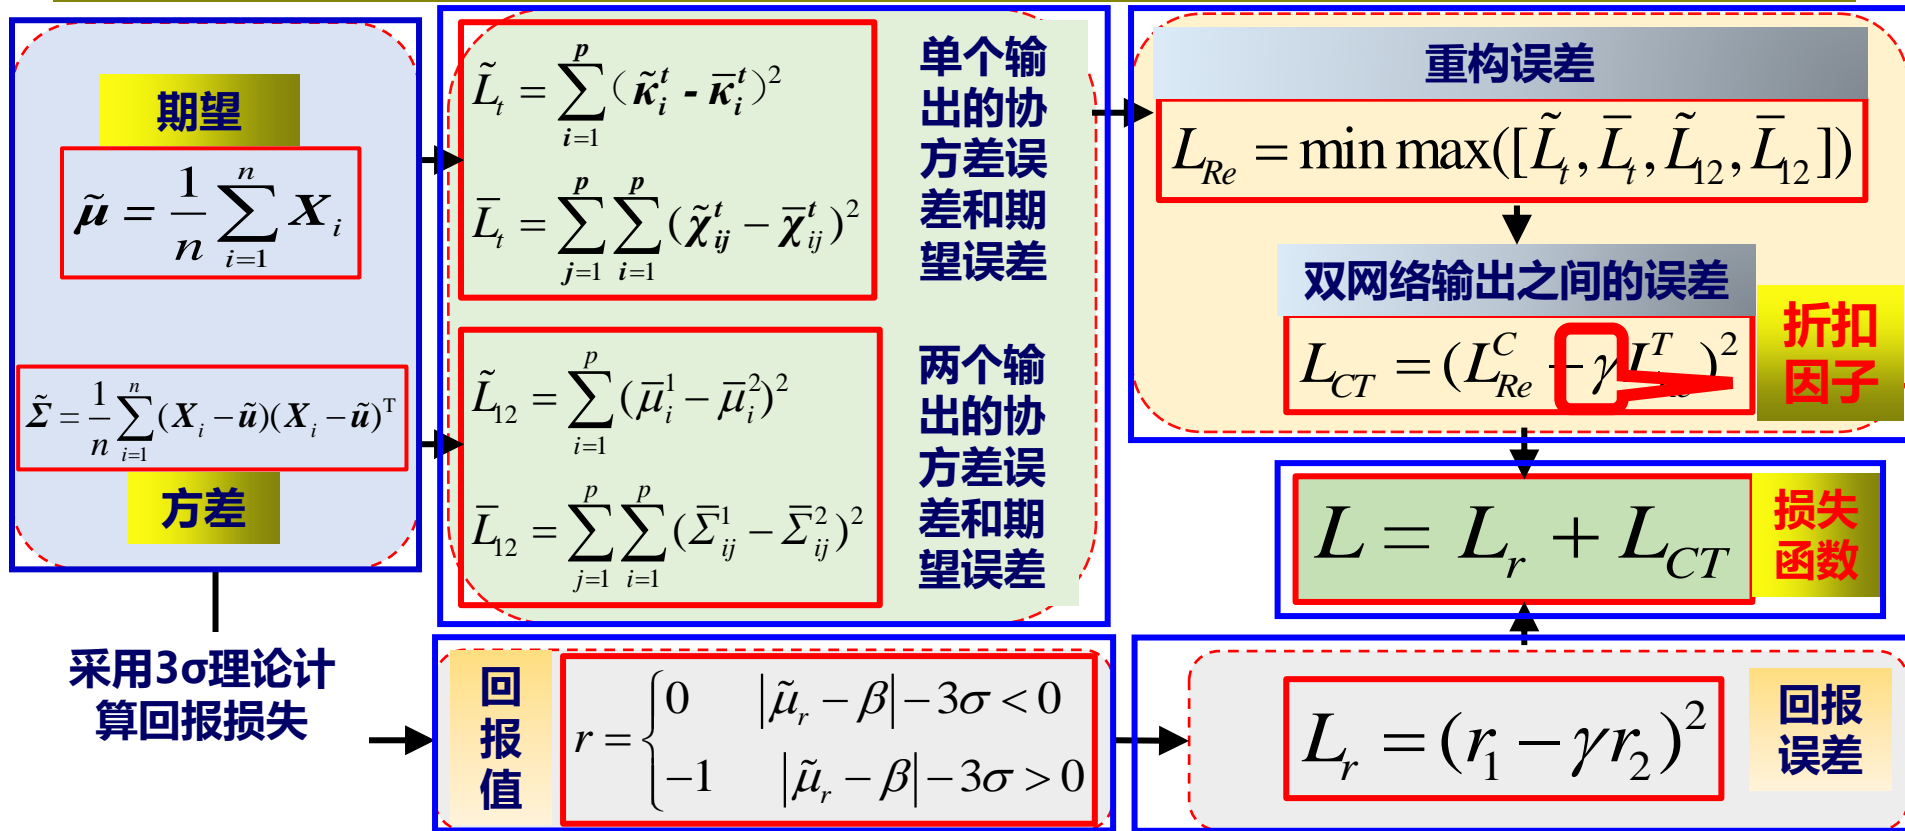
该方法仅利用正常样本数据完成模型的训练，采用 3σ 理论建立异常检测阈值，实现了高精度的异常检测。



无故障样本的滚动轴承故障异常检测

第二章

关键技术——融合回报损失和重构误差的新损失函数




无故障样本的滚动轴承故障异常检测


第二章

公开图像数据集的验证——Mnist、Cifar10、Fashion-Minst、SVHN

Mnist:数字识别数据集, 由 70000 个大小为 28×28 的手写灰度数字图像组成。训练集包含 60000 个样本和测试集包含 10000 个样本。



Cifar10: 日常生活中的对象图片。它由 60000 张 32×32 大小的 10 类彩色图像组成, 每类 6000 张图像。



Fashion-Minst: 数据集包含 10 个类别, 每个样本的大小为 28×28 灰度图像。



SVHN: 街景图像的房屋编号数据集, 由 600000 个数字图像组成



无故障样本的滚动轴承故障异常检测

第二章

公开图像数据集的验证——不同数据预处理方法及检测器对结果的影响

L2正则化

L1正则化

SVDD检测器

GMM检测器

PCA检测器

ECOD检测器

去均值

归一化

不处理

Mnist(%)

Cifar10(%)

Fashion-minst(%)

SVHN(%)

①

②

③

④

①

②

③

④

①

②

③

④

①

②

③

④

L1

95.7

94.5

92.6

95.1

74.9

74.3

72.8

75.5

93.6

91.8

90.6

92.4

57.5

57.2

56.4

57.8

L2

96.3

95.4

93.2

96.5

62.3

60.6

57.8

63.1

91.9

91.5

91.2

92.1

57.9

55.6

52.1

58.9

ZC

97.4

96.6

95.3

97.7

70.9

68.9

67.8

71.4

92.8

92.2

91.3

93.3

61.8

61.4

58.2

62.7

MN

97.5

94.7

90.6

97.8

68.9

65.6

63.4

69.4

93.4

91.3

89.2

93.8

64.1

62.6

57.3

64.4

RD

97.3

97.2

94.6

97.6

65.8

66.5

63.8

67.7

91.5

92.6

91.4

93.3

57.9

56.3

54.7

58.2

- 结论: 1.不同的异常检测器, 采用不同的数据预处理方法后, 异常检测结果也不相同。
2.采用异常检测器ECOD的检测精度要明显优于其余三种检测器的检测精度。后续验证中均采用ECOD检测器。
3.对于不同的数据集, 为了提高检测精度, 需要采用不同的数据预处理方法。

公开图像数据集的消融试验——经验池结构、折扣因子对检测结果的影响

γ	Mnist(MN)		Cifar10(L1)		Fashion-minst(MN)		SVHN(MN)	
	有经验池	无经验池	有经验池	无经验池	有经验池	无经验池	有经验池	无经验池
0.0	96.1	95.1	70.4	68.6	92.1	91.5	62.5	61.7
0.1	96.2	96.0	71.6	71.4	92.5	91.8	63.0	62.1
0.2	96.6	95.8	72.8	70.2	92.4	91.7	63.4	62.5
0.3	96.4	95.9	73.3	70.3	92.8	92.0	63.4	62.8
0.4	96.8	96.4	73.3	71.6	93.0	92.2	63.8	62.9
0.5	97.0	96.6	73.9	72.2	93.2	92.4	64.0	63.1
0.6	97.2	96.8	74.3	72.6	93.4	92.6	64.2	63.3
0.7	97.4	97.0	74.5	73.0	93.5	93.0	64.3	64.0
0.8	97.5	97.1	74.5	73.1	93.5	93.0	64.3	64.0
0.9	97.8	97.6	75.5	73.6	93.8	92.9	64.4	63.9
0.95	97.6	97.7	74.9	73.1	93.7	93.3	64.5	64.2

结论：不同的 γ 值对模型的影响程度不同，但是随着 γ 值的增加在四种数据集上模型的检测精度均随之增大,最优值是在0.8-0.95之间。此外，**有经验池**的检测精度要普遍**高于无经验池结构**的检测精度。说明本文所提出的损失函数的各个组成部分是**缺一不可**的。

无故障样本的滚动轴承故障异常检测

第二章


滚动轴承故障数据集的验证

西储大学试验器



12100Hz

IMS试验器



25600Hz

带机匣的发动机转子试验器



31200Hz

滚动轴承疲劳试验机

BMD6009



51200Hz



C&U61807



航空发动机的主轴承故障



200000Hz





无故障样本的滚动轴承故障异常检测

第二章

公开滚动轴承故障模拟数据集的验证——美国凯斯西储大学的滚动轴承数据集

样本信息	损伤位置	样本量 (个)	
		训练集	测试集
	正常	543	135
	内圈	0	692
	滚动体	0	692
	外圈	0	528

方法	DADDRL	DSVDD	OC-NN	ANOGAN	SVDD
AUC (%)	98.2	95.8	93.9	96.2	91.3

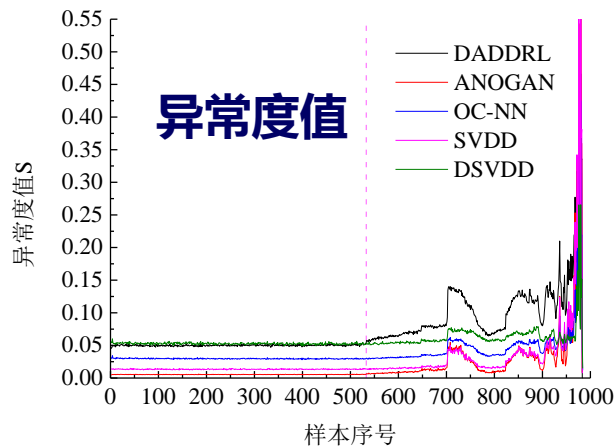


结论：本文最终的检测精度为 98.2%。次优的ANOGAN检测精度为 96.2%。相比提高了 2%。

公开滚动轴承故障模拟数据集的验证——IMS滚动轴承全寿命周期振动数据

样本信息：试验共采集样本数据984份，将前300个样本作为正常类样本，用于模型的训练，利用所有的样本数据进行测试。

信号	DADDRL	SVDD	DSVDD	ANOGAN	OC-NN
异常样本序号	<u>533</u>	699	647	<u>533</u>	647
阈值	<u>0.053</u>	0.015	0.056	<u>0.006</u>	0.03
AUC (%)	<u>100.0</u>	62.7	84.6	<u>100.0</u>	84.6



结论：在第533个样本前所有样本的异常度值均很稳定。1) DADDRL和ANOGAN方法在第533个样本后开始出现增大的趋势；2) 第647个样本后DSVDD和OC-NN开始出现增长趋势；3) 出现增长趋势最晚的是SVDD方法。

无故障样本的滚动轴承故障异常检测

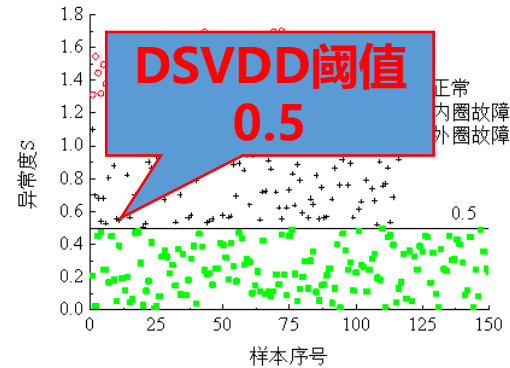
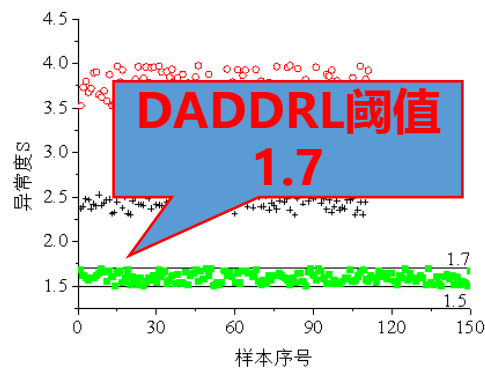
第二章

南京航空航天大学IDES研究室带机匣的航空发动机转子试验器轴承故障数据集的验证

样本信息	轴承状态	转速	样本数量
	正常	2400rpm	150
	外圈故障	2400rpm	116
	内圈故障	2400rpm	110

检测结果	故障	<u>本方法</u>	DSVDD	OCNN	ANOGAN	SVDD
	外圈	100	99.7	98.4	98.6	96.8
	内圈	100	99.6	99.6	98.8	97.8

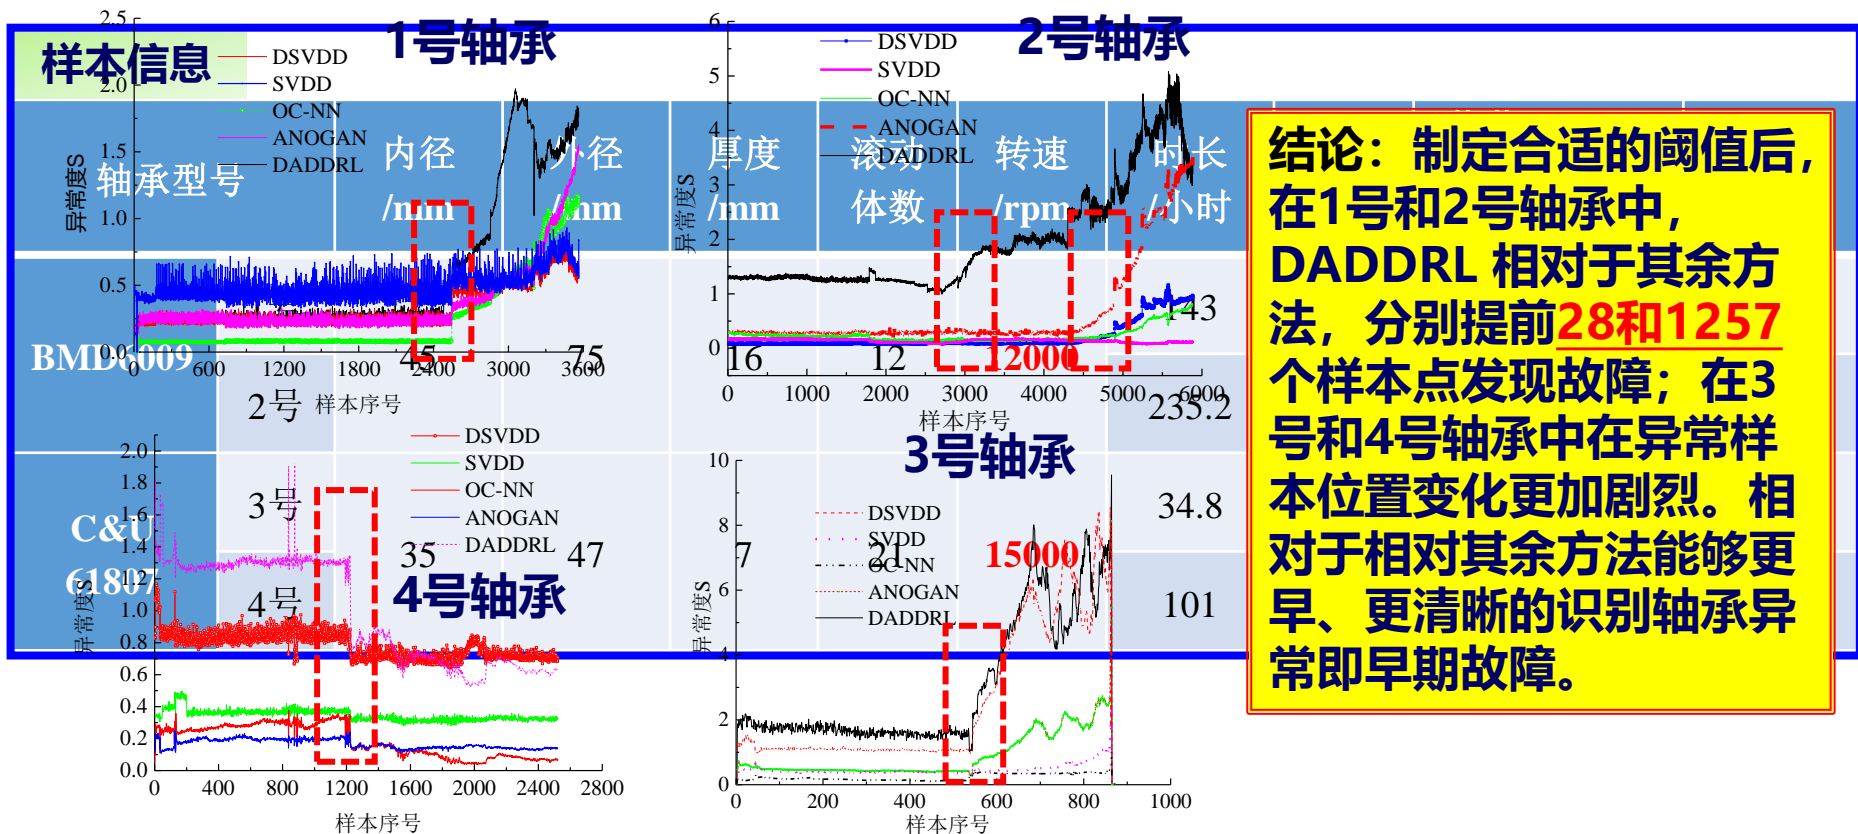
结论：对于DADDRL,阈值设置为**1.7**时可以完全区分正常和异常样本；
对于DSVDD,阈值设置为**0.5**时不能很好的区分正常和异常样本；



无故障样本的滚动轴承故障异常检测

第二章

南京航空航天大学IDES研究室基于滚动轴承疲劳试验机的滚动轴承故障演化试验验证

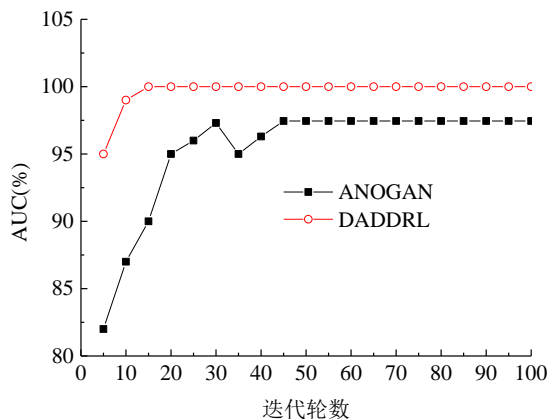


基于实际航空发动机的主轴承故障异常检测方法验证

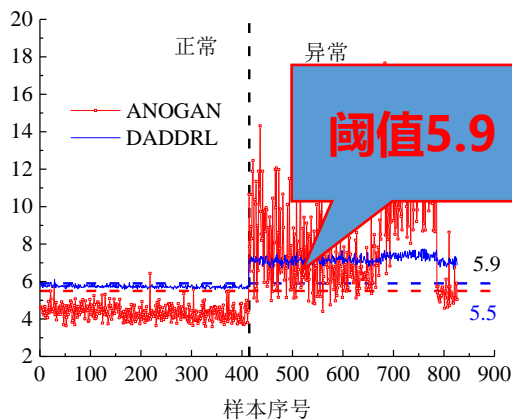
轴承状态	转速	样本数量
正常	>13000rpm	413
外圈故障	>13000rpm	413

故障	<u>本方法</u>	DSVDD	OCNN	ANOGAN	SVDD
外圈	100.0	96.49	91.84	85.32	82.65

精度变化曲线



异常度值




结论：当制定阈值为5.9时可以完全将正常和异常进行区分。

无故障样本的滚动轴承故障异常检测

第二章


基于实际航空发动机的主轴承故障异常检测方法验证

利用前面训练完成的模型，在另外两台同型号的发动机数据集上验证模型的泛化性能。



发动机编号	01	02	03
轴承状态	正常	异常	异常
样本数量	826	300	869

本方法异常度值



结论

- ◆ 阈值: 5.9
- ◆ 01号发动机: 检测精度100%;
- ◆ 02号发动机: 检测精度98.62%
- ◆ 03号发动机: 检测精度96.73%
- ◆ 平均: 测试精度98.45%。

◆ 提出了一种融合深度强化学习和深度一类分类的异常检测方法

将深度强化学习和深度一类分类方法相融合，提出了融合深度强化学习的异常检测方法DADDRL。在公开的图像数据集以及多个滚动轴承数据集上对本文方法进行了充分的验证。结果表明本文方法具有较高的异常检测精度。

◆ 提出了一种融合回报损失和重构误差的新损失函数

采用 3σ 理论计算了回报损失同时计算了双输入网络的重构误差，将二者进行结合提出了融合回报损失和重构误差的新损失函数。验证结果表明，所提的损失函数中各个部分均对结果有一定程度的影响，各部分缺一不可。

◆ 建立了双网络结构异常检测新框架

分析认为，采用双网络结构的检测效果要明显的优于单网络结构的检测效果。此外无论是在图像数据集还是滚动轴承数据集上，所提方法均具有很好的异常检测能力，说明了本文方法是一种通用的异常检测方法。

目录

1

绪论

2

无故障样本的滚动轴承故障异常检测

3

含少量故障样本的滚动轴承故障诊断

4

低速转动状态下滚动轴承故障异常检测

5

基于振动和油液的滚动轴承故障智能融合诊断

6

总结与展望

研究目的：故障类样本数量少导致的诊断精度低以及模型训练速度慢的问题

解决方案

(1) **双经验池深度强化学习方法**,该方法主要用于解决数据不平衡下诊断精度不足的问题;

(2) **对冲残差网络**,该方法主要是为了提高少样本下模型的训练速度;

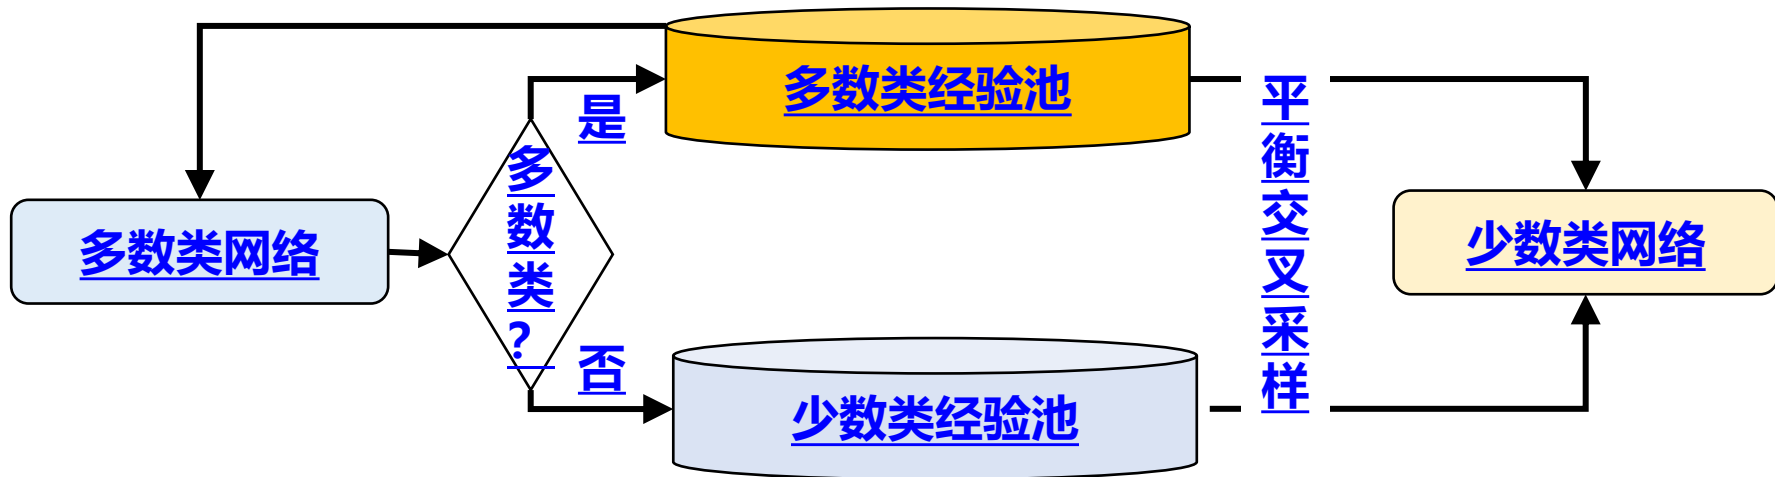
(3) **多任务残差网络方法**,该方法主要是为了同时识别故障部位、故障状态、损伤大小。

结果验证

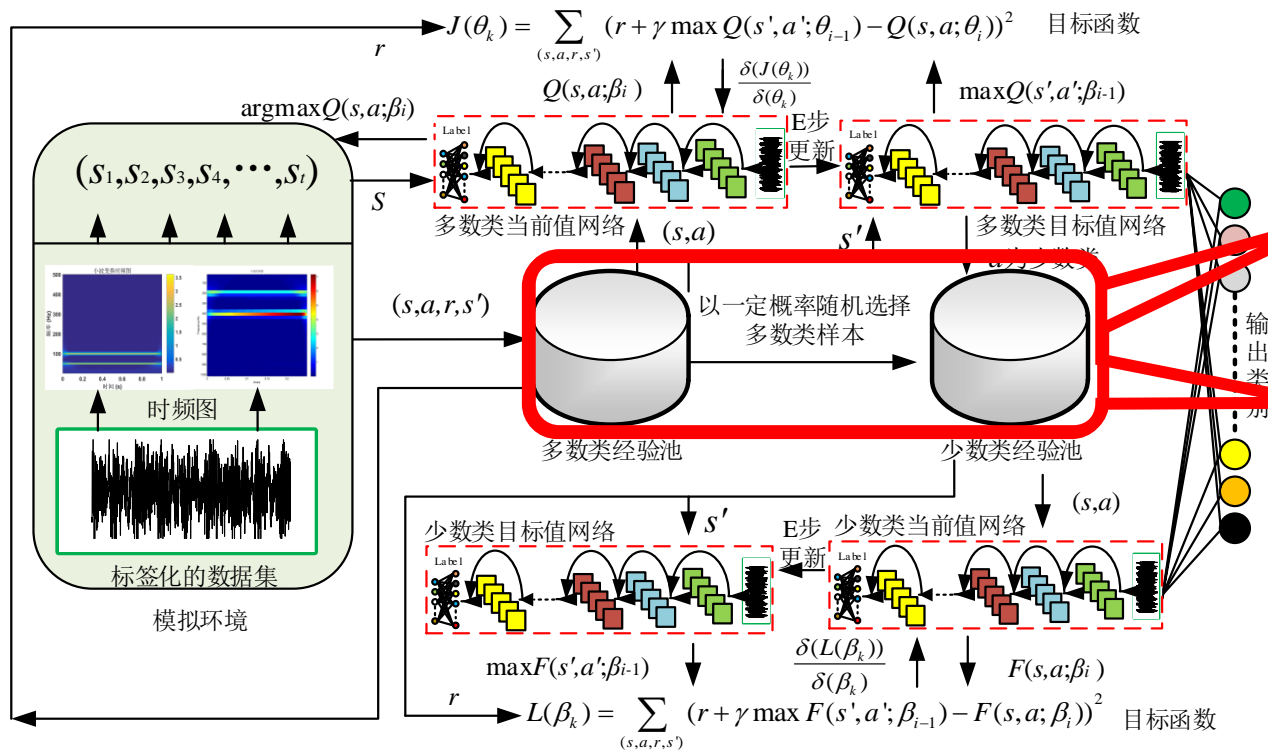
- ◆ **公开的图像数据集验证**
- ◆ **美国凯斯西储大学的滚动轴承数据集验证**
- ◆ **带机匣的航空发动机转子试验器的方法验证**
- ◆ **基于实际航空发动机主轴承的故障诊断方法验证**

(1) 双经验池深度强化学习方法基本原理

- ◆ 采用两种网络（称为多数类和少数类网络）分别完成多数类和少数类样本的分类任务。采用双经验池结构分别存储多数类样本和少数类样本。
- ◆ 将多数类网络识别错误的样本存储在少数类的经验池中。
- ◆ 对于多数类网络直接从多数类经验池中抽取数据，完成模型的训练
- ◆ 对于少数类网络采用平衡交叉采样策略从多数类和少数类样本中分别抽取部分数据完成模型的训练，抽取的数据中认为多数类和少数类数据量相当。



(1) 双经验池深度强化学习方法关键技术

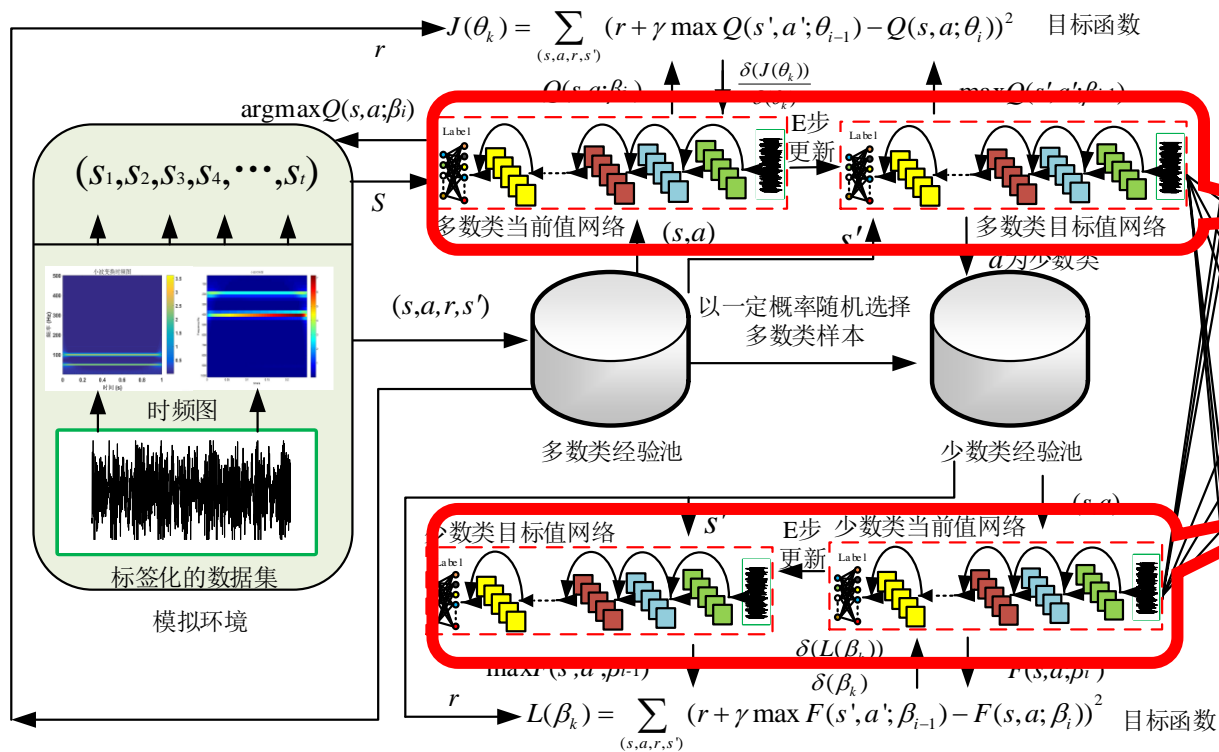


(1) 双经验池
结构分别存储多数类样本和少数类样本

(2) 平衡交叉
采样分别从多数类和少数类样本中分别抽取部分数据达到类间数据平衡的目的

(1) 双经验池深度强化学习方法关键技术

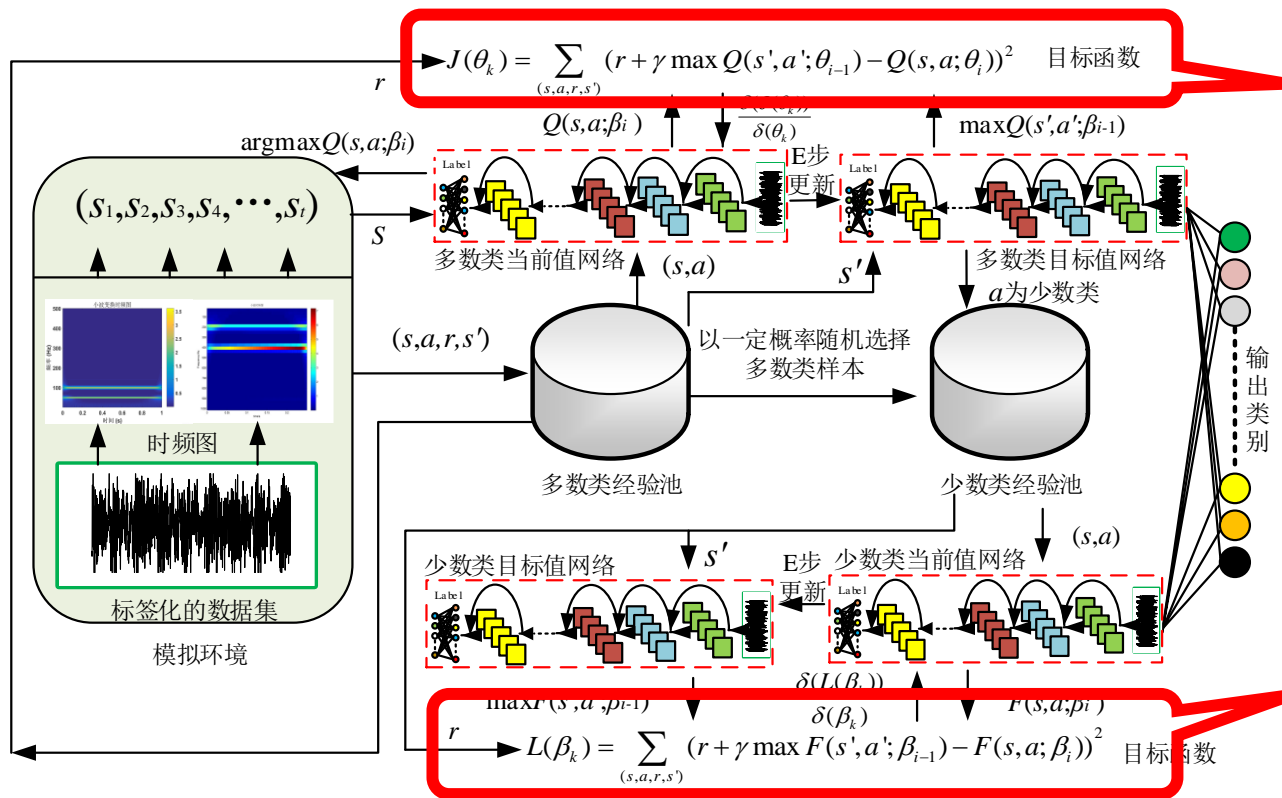
第三章



(3) 双并行残差网络
主要服务于两种经验池，通过在两种经验池中采样，分别训练两种残差网络，其中多数类网络主要用于对多数类的识别，少数类网络主要用于对少数类的分类同时兼顾对多数类网络错误识别样本的诊断。最终分类结果是双并行残差网络的和。

(1) 双经验池深度强化学习方法关键技术

第三章



(4) 带扰动因子的目标损失函数

$$r = \begin{cases} 1 & a_t = l_t \\ -1 & a_t \neq l_t \end{cases}$$

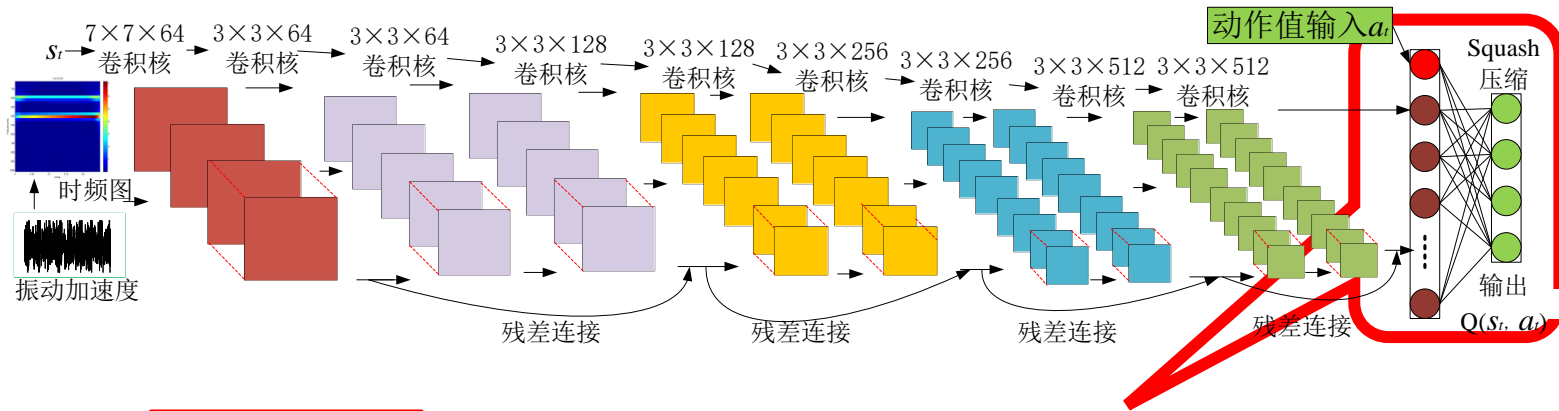
原奖励函数

$$r = \begin{cases} 1 - \eta_1 & a_t = l_t \\ -1 - \frac{|a_t - l_t|}{\max(a_t, l_t)} - \eta_2 & a_t \neq l_t \end{cases}$$

$$y_i = r + \gamma \max_{a'} Q(s', a'; \theta'_i)$$

损失函数

(5) 改进的深度残差网络



$$v_j = \frac{\|s\|^2 s_j}{1 + \|s\|^2 \|s\|}$$
$$v_j \approx \frac{s_j}{\|s\|} \quad \|s\| \rightarrow 0$$
$$v_j \approx \frac{s_j}{\|s\|} \quad \|s\| \rightarrow +\infty$$

Squash函数

- ◆ 采用**Squash函数**将输出标签压缩至**0-1**的范围内。摒弃了传统**Softmax函数**
- ◆ 将上一步预测的**标签值**和**输出值**相融合进行进一步的学习。

(1) 双经验池深度强化学习方法验证 **图像数据集**

第三章

验证条件：多数类和少数类的数据样本比例 ρ 分别为100%、25%、10%



数据集 (少数类标签)	ρ (%)	各种算法在测试集上的测试精度 (%)				
		Resnet18	DQNimb	DCNN	DQN	本文方法DEPDRL
Mnist	100	99.7	99.6	99.3	99.2	<u>99.7</u>
Cifar-10	100	91.6	88.7	83.5	85.4	<u>94.7</u>
Fashion-Mnist	100	95.3	92.1	92.3	93.7	<u>96.4</u>
Mnist (0/1)	10	95.3	96.6	94.3	95.1	<u>98.1</u>
	25	98.2	99.2	97.1	97.1	<u>99.6</u>
Cifar-10 (0/1)	10	53.9	58.17	50.4	53.62	<u>66.9</u>
	25	59.6	62.4	52.6	58.2	<u>69.6</u>
Fashion-Mnist (0/1)	10	81.4	87.65	78.6	80.27	<u>91.1</u>
	25	87.3	91.5	86.7	88.6	<u>93.6</u>
Mnist (odd)	10	97.3	97.9	96.8	97.4	<u>98.7</u>
	25	98.1	98.9	97.9	98.6	<u>99.3</u>
Cifar-10 (odd)	10	45.7	46.6	41.3	43.8	<u>51.7</u>
	25	55.9	57.8	50.2	52.9	<u>63.8</u>
Fashion-Mnist (odd)	10	85.6	86.9	82.2	84.4	<u>91.8</u>
	25	90.3	91.6	87.1	88.7	<u>93.2</u>
Mnist (even)	10	97.2	98.0	97.6	97.2	<u>98.6</u>
	25	97.7	98.9	97.5	97.9	<u>99.2</u>
Cifar-10 (even)	10	46.9	47.0	44.1	45.3	<u>52.4</u>
	25	57.1	58.1	53.2	54.4	<u>65.3</u>
Fashion-Mnist (even)	10	85.3	86.2	83.6	84.3	<u>90.6</u>
	25	89.7	90.5	85.8	88.4	<u>92.5</u>

结论：在两种不平衡比例下相比其余三种方法的分类精度提高5%以上。表明本方法在不平衡数据分类过程中相比其他方法更具优势。

(1) 双经验池深度强化学习方法验证 西储数据集

第三章

输入：小波时频图



不平衡比例 100%、25%、20%、15%、10%、5%、1%


ρ (%)	训练集				测试集	
	内圈	外圈	滚动体	正常	故障	正常
<u>100</u>	3234	2431	3231	2828	2225	707
<u>25</u>	809	608	808	2828	2225	707
<u>20</u>	647	486	646	2828	2225	707
<u>15</u>	485	365	485	2828	2225	707
<u>10</u>	323	243	323	2828	2225	707
<u>5</u>	162	122	162	2828	2225	707
<u>1</u>	32	24	32	2828	2225	707
标签	0	1	2	3	待诊断	

(1) 双经验池深度强化学习方法验证 西储数据集

第三章

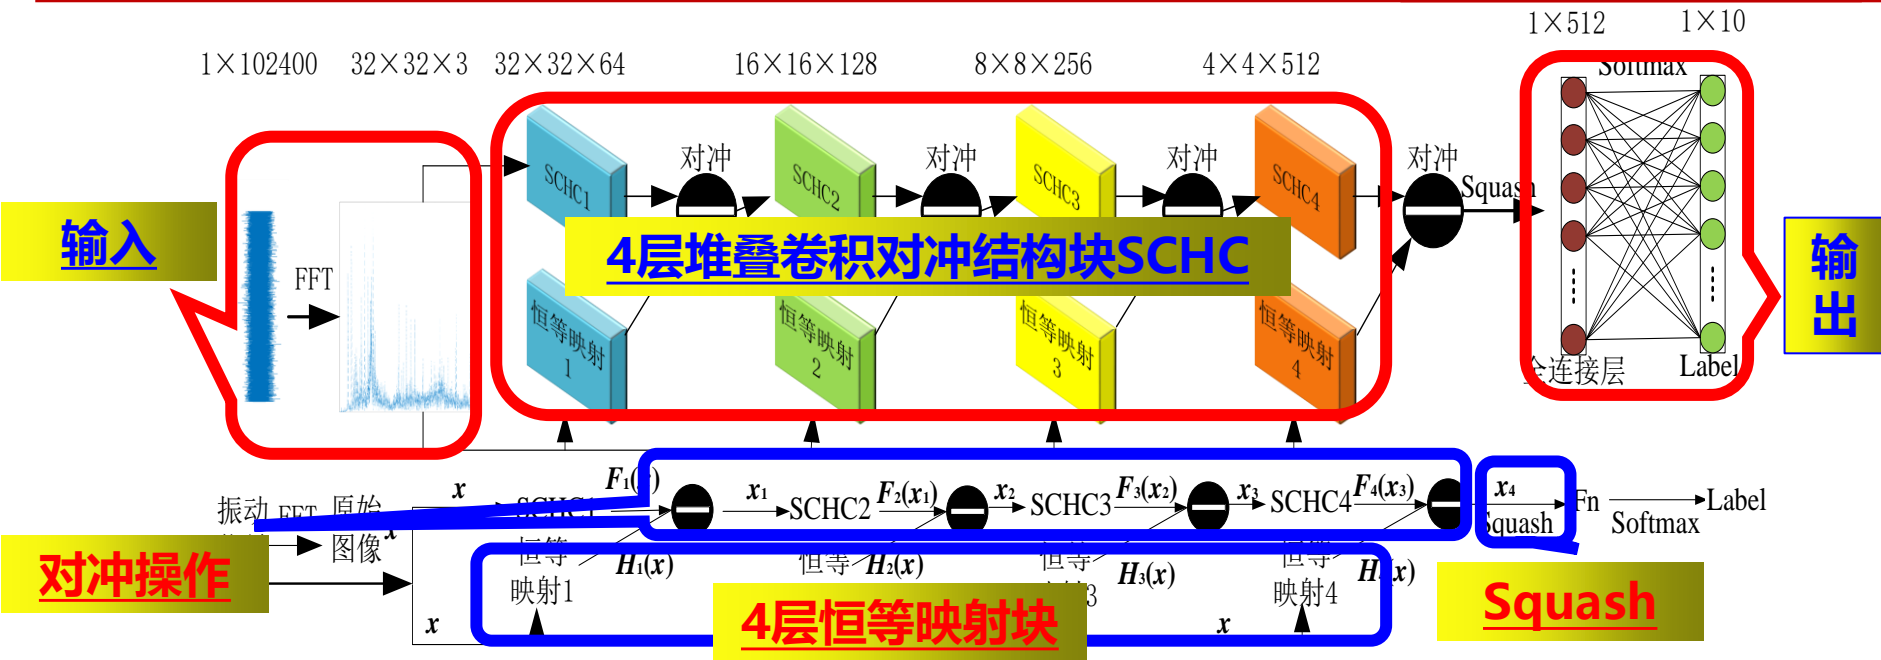
ρ (%)	测试精度 (%)			
	Resnet18	DQNimb	DQN	<u>DEPDRL</u>
100	99.62	98.92	98.65	<u>99.68</u>
25	89.44	92.37	87.34	<u>96.78</u>
20	87.65	91.34	84.86	<u>95.84</u>
15	87.36	89.94	80.97	<u>95.71</u>
10	86.57	89.34	80.16	<u>94.72</u>
5	82.37	85.64	78.82	<u>91.19</u>
1	69.76	73.87	65.35	<u>86.67</u>

不同 ρ 下分类准确率变化情况



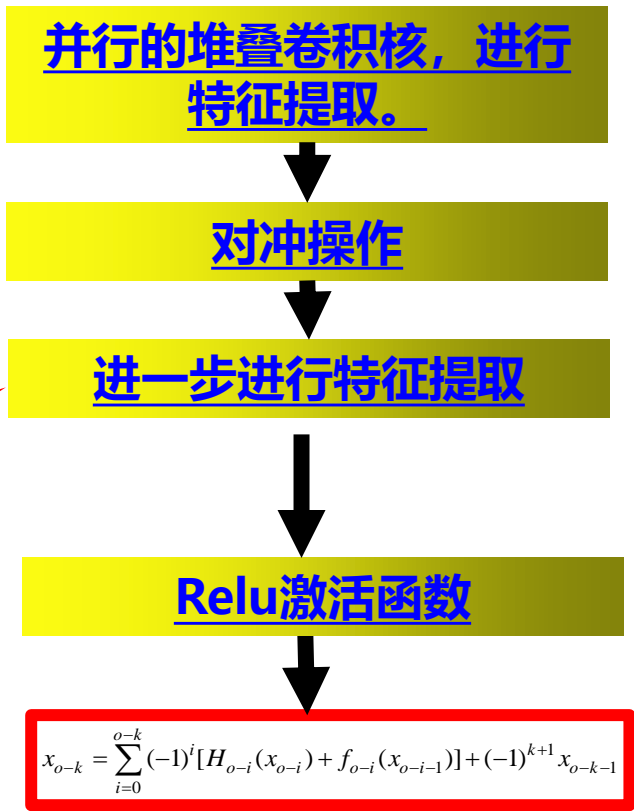
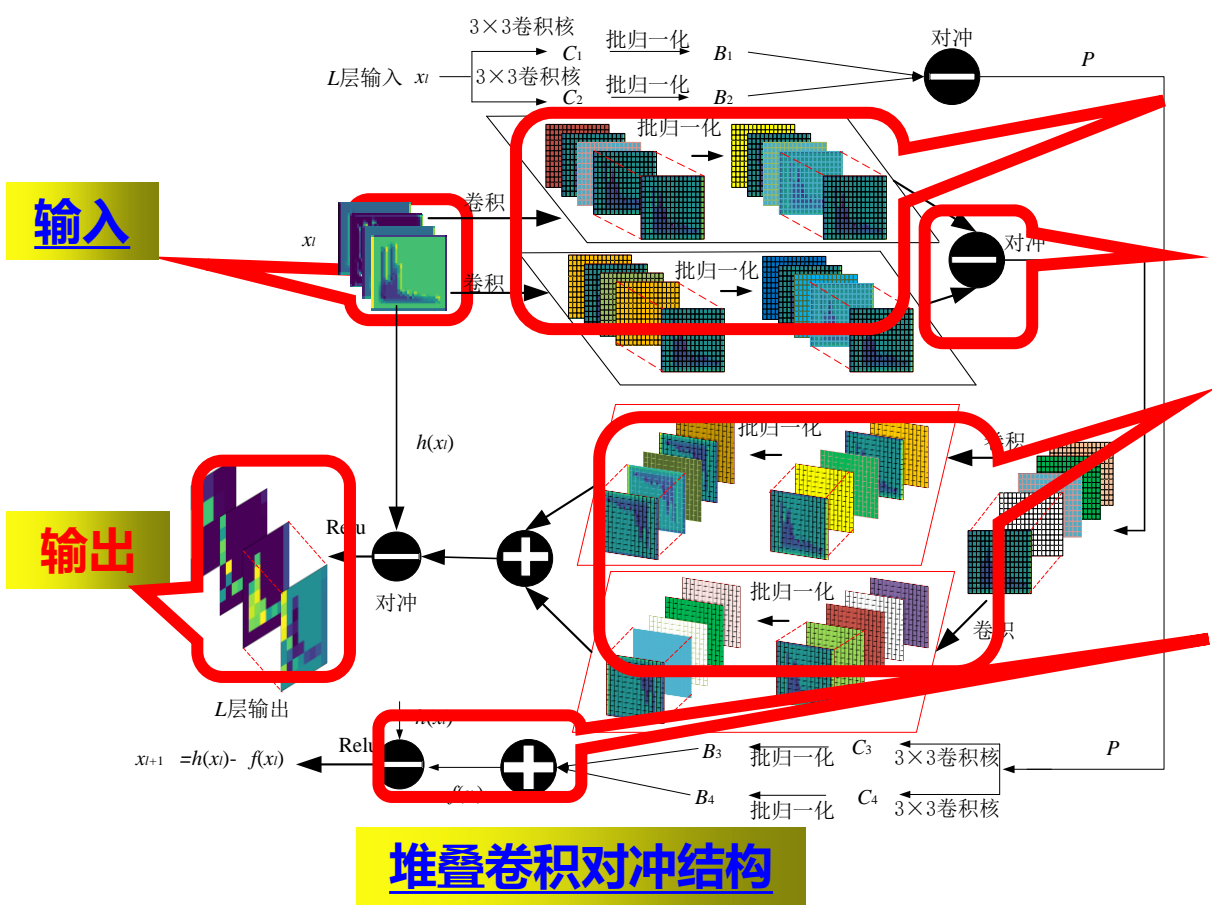
结论：随着不平衡比率范围的增大 (ρ 值减小)，各个模型的诊断精度均有所降低，DEPDRL的减小范围较小。该方法在考虑算法层面的改进同时，考虑了数据层面的平衡交叉采样方案，使得算法对于少数类的识别能力增强，从而提高了分类准确率。

(2) 对冲残差网络基本框架




- ◆ 输入为滚动轴承一维时域信号通过FFT得到的频谱图，输出为轴承故障类别。
- ◆ 关键点：4层堆叠卷积对冲结构块SCHC、4层恒等映射块、对冲操作、Squash压缩函数、Fn全连接层。

(2) 对冲残差网络关键技术



(2) 对冲残差网络关键技术

第三章







将起始输入经过特定的恒等映射模块与上文所提出的堆叠卷积对冲结构块相结合，形成新的对冲模块，使得下一层可以同时接收来自原始图像的部分特征和上层对冲结构块的输出，从而强化了各层学习特征的能力。

(2) 对冲残差网络验证图像数据集

第三章

数据集	模型名称	精度(%)	时间 (s)
Cifar-10	Resnet18	90.58	5478.76
	Resnet34	92.34	8563.59
	DResHnet	94.28	3970.21
Mnist	Resnet18	98.23	1264.53
	Resnet34	99.19	1576.67
	DResHnet	99.61	951.34



**结论: Mnist DResHnet在精度上提高约0.042%, 计算时间缩短约24.76%;
Cifar-10 DResHnet在精度上提高约1.94%, 计算时间缩短约27.53%。**

(2) 对冲残差网络验证西储大学轴承数据集



第三章

模型名称	精度(%)	迭代次数	计算时间 (s)
CNN	98.64	82	212.38
Alexnet	99.36	67	234.52
Resnet18	99.62	22	264.64
Resnet34	100	14	702.37
DResHnet	100	9	176.32

结论:

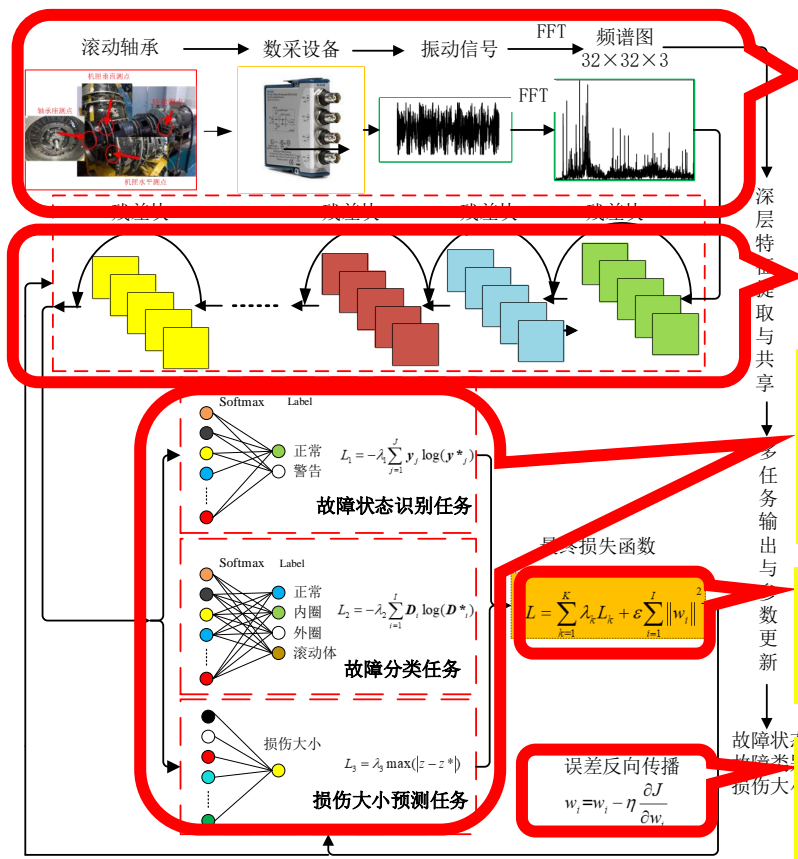
(1) 达到99%诊断精度时, 收敛速度至少提高1/3;

(2) 带对冲结构的残差网络模型DresHnet可以加快收敛速度, 提高算法的精度



(3) 多任务深度残差网络基本框架

研究目的:
提出一种多任务诊断的深度残差网络模型MDResnet, 具有故障状态、部位分类与损伤大小预测的功能。



数据预处理: 采用FFT算法获得频谱图

深度残差网络进行特征提取

全连接层实现故障状态识别、故障部位诊断和损伤大小预测任务

计算各个任务的损失大小 L_k 联合损失 L


基于误差反向传播算法进行参数更新

深层特征提取与共享 → 多任务输出与参数更新 → 故障状态识别、故障部位诊断、损伤大小

(4) 多任务深度残差网络验证西储数据集

第三章

样本信息



结论: 损伤大小预测的最大绝对误差0.0035mm,而其他算法最好的结果为0.0345mm,约为本文算法的10倍。

(5) 带机匣的航空发动机转子试验器的方法验证

第三章


样本信息

不平衡比率 ρ	训练集				测试集	
	内圈	外圈	滚动体	正常	故障	正常
100	6896	7376	7808	8272	5520	2068
25	1724	1844	1952	8272	5520	2068
20	1379	1475	1562	8272	5520	2068
15	1034	1106	1171	8272	5520	2068
10	690	738	781	8272	5520	2068
5	345	369	390	8272	5520	2068
1	69	74	78	8272	5520	2068
标签	0	1	2	3	待诊断	

验证条件：数据划分比例**1:4**，数据预处理方法——**小波时频分解的时频图**。采用多种不平衡比率 ρ 在故障数据集上进行不平衡数据的划分。

(5) 带机匣的航空发动机转子试验器的DEPDRL验证



ρ	测试精度 (%)			
	Resnet18	DQNimb	DQN	<u>DEPDRL</u>
100	97.56	97.32	96.54	<u>98.86</u>
25	91.37	93.27	89.62	<u>95.12</u>
20	90.65	90.97	88.36	<u>95.23</u>
15	87.23	88.33	84.68	<u>93.28</u>
10	84.49	86.27	78.39	<u>90.64</u>
5	79.92	81.68	73.89	<u>88.83</u>
1	65.39	72.18	60.67	<u>78.23</u>



结论:

- (1) 以 $\rho=5$ 为例, DEPDRl的分类精度达到88.83%, 相比分类精度较高的DQNimb提高了7.15%。
- (2) 随着不平衡比率范围的增大 (ρ 值减小), 各个模型的诊断精度均有所减小。
- (3) DEPDRl在不平衡故障数据中具有更高的分类精度。

(5) 带机匣的航空发动机转子试验器的DResHnet验证







方法	准确率 (%)
CNN+矩阵图	92.44%
CNN+峭度图	93.58%
SVM	86.16%
文献2方法	96.32%
Resnet18	97.56%
Resnet34	98.43%
DResHnet	100%

结论: (1) DresHnet诊断精度为**100%**, 相比其他几种算法具有更高的诊断精度;
 (2) DresHnet的收敛速度相比较快的Resnet18速度提高了约**21.17%**, 说明DresHnet具有更快的收敛速度;

(5) 带机匣的航空发动机转子试验器的MDResnet验证

第三章



结论: (1) 传统DNN算法, 状态识别精度为93.55%, 部位诊断精度为90.53%, 尺寸预测误差为0.262mm。

(2) CNN, 其分类精度为96.67%, 尺寸预测误差为0.120mm。

(3) 本文的多任务残差网络, 分类精度99.11%, 部位诊断精度99.05%, 尺寸预测误差0.020mm, 相比CNN, 状态识别和部位诊断精度分别提高约3%、5%的同时, 损失大小预测效果提高了6倍左右。

(5) 实际航空发动机主轴承故障数据的方法验证

比率	训练集		测试集	
	外圈	正常	故障	正常
100	331	331	457	82
90	297	331		
80	264	331		
70	231	331		
60	198	331		
50	165	331		
40	132	331		
30	99	331		
25	82	331		
20	66	331		
15	49	331		
10	33	331		
5	16	331		
1	3	331		
标签	1	0		

验证条件:

- ◆ 数据划分比例**1:4**;
- ◆ 预处理方法——**FFT**, 将前50176个频谱点转换为 $224 \times 224 \times 1$ 的灰度图。
- ◆ 采用多种**不平衡比率** ρ 在故障数据集上进行不平衡数据的划分。

(5) 实际航空发动机主轴承故障数据的方法验证

第三章

ρ (%)	测试精度 (%)						本文	本文	本文
	Resnet18	CNN	DQNimb	DQN	SVM	ViT	DEPDRL	DresHnet	MDResnet
1	72.23	59.49	62.35	55.23	45.57	83.45	93.82	77.93	70.21
5	81.17	67.75	68.55	56.59	50.47	88.93	95.96	83.97	81.07
10	80.5	74.15	75.96	58.04	54.98	88.24	96.23	84.91	82.59
15	82.85	71.21	76.05	62.09	60.85	89.86	96.74	83.48	81.17
20	84.71	74.76	78.65	61.36	64.62	90.03	97.7	88.64	83.47
25	93.73	84.38	84.66	67.34	68.95	92.34	98.64	92.12	90.13
30	92.84	83.54	85.46	73.04	68.49	91.94	99.72	94.63	89.57
40	93.98	83.09	84.9	71.71	71.87	94.76	98.63	95.81	92.25
50	91.81	79.04	85.91	77.45	75.34	95.0	99.83	94.34	93.19
60	95.9	84.5	86.9	84.69	76.28	96.92	98.56	95.73	94.89
70	93.86	90.87	90.72	83.34	79.38	98.26	99.43	96.62	94.25
80	94.51	90.69	92.43	88.65	81.54	99.15	99.67	97.47	95.43
90	95.25	90.51	90.96	87.24	80.29	100.0	100.0	97.60	96.12
100	98.51	92.6	94.89	89.25	83.65	100.0	100.0	98.26	97.98

结论:

(1) 在 ρ 值从1%变化至100%的过程中DEPDRL均表现出了最好的诊断效果

(2) 在 ρ 值小于20%时,DEPDRL相比此时最优的诊断算法VIT提高了约7%的诊断精度。

(3) 在极端不平衡样本下,DEPDRL方法的诊断效果表现最优,其次是VIT模型,然后是DresHnet。

(4) 随着 ρ 值的增加,样本不平衡情况逐渐消失,所有模型的诊断精度均有不同程度的增大。

◆ 提出了多任务深度残差网络方法

所提多任务深度残差网络模型展现了同时对故障状态识别、故障部位诊断与损伤大小识别的优势。说明本文所提的多任务模型具有较高的诊断精度与损伤大小预测能力，且模型具有很好的泛化性能，也表明该网络具有较好的应用前景。

◆ 提出了双经验池深度强化学习方法

建立的DERDRL模型创新性地提出了双并行残差网络模型结构和双经验池，其中双经验池用于存储不平衡数据，通过平衡交叉采样的方法将不平衡数据变为平衡数据。在不同数据集上与其他方法的对比结果充分证明了本文所提出的DEPDRL方法在处理不平衡样本的问题上更具优势，同时也表明该网络具有很好的工程应用前景。

◆ 提出了深度对冲残差网络

在标准数据集和滚动轴承故障数据集上，本文所提出的深度残差对冲网络DresHnet在诊断精度和收敛速度方面均展现出很强的优势，同时，也表明该网络具有很好的工程应用前景。

目录

1

绪论

2

无故障样本的滚动轴承故障异常检测

3

含少量故障样本的滚动轴承故障诊断

4

低速转动状态下滚动轴承故障异常检测

5

基于振动和油液的滚动轴承故障智能融合诊断

6

总结与展望

故障特征频率分析——基于带机匣转子试验器的低转速滚动轴承故障模拟试验

部分
样本
信息


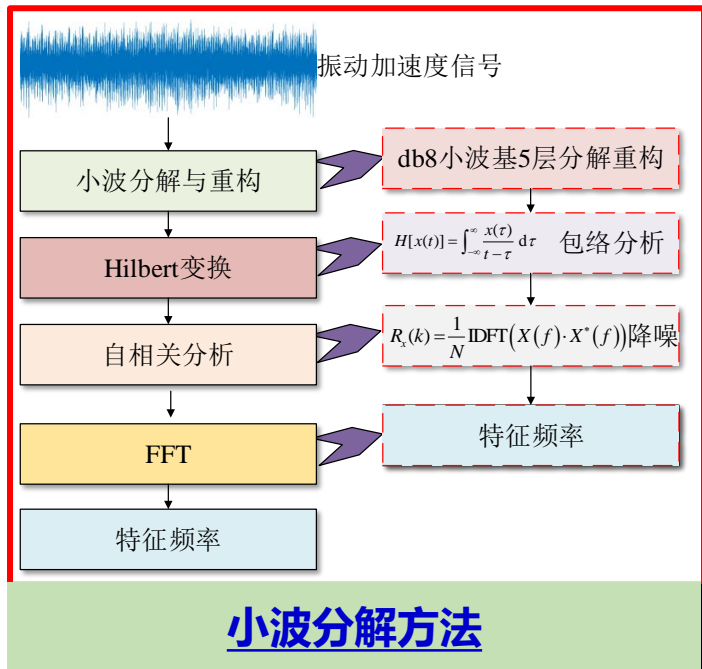
试验	轴承状态	转速	样本数量
第一次试验	正常	120rpm	609
		摇转	609
	外圈故障	120rpm	409
		摇转	548
	内圈故障	120rpm	120
第二次试验	正常	120rpm	396
		摇转	253
	外圈故障	120rpm	260
		摇转	206
	内圈故障	120rpm	300
		摇转	304

◆ 2022年7-12月完成，共进行了四次试验；(B&K4805)振动加速度传感器；NI USB9234数据采集器；采样频率为25600Hz

低速转动状态下滚动轴承故障异常检测

第四章




故障特征频率分析——基于带机匣转子试验器的低速滚动轴承故障模拟试验




低速转动状态下滚动轴承故障异常检测

第四章

故障特征频率分析——基于真实航空发动机机匣测点信号的故障数据分析



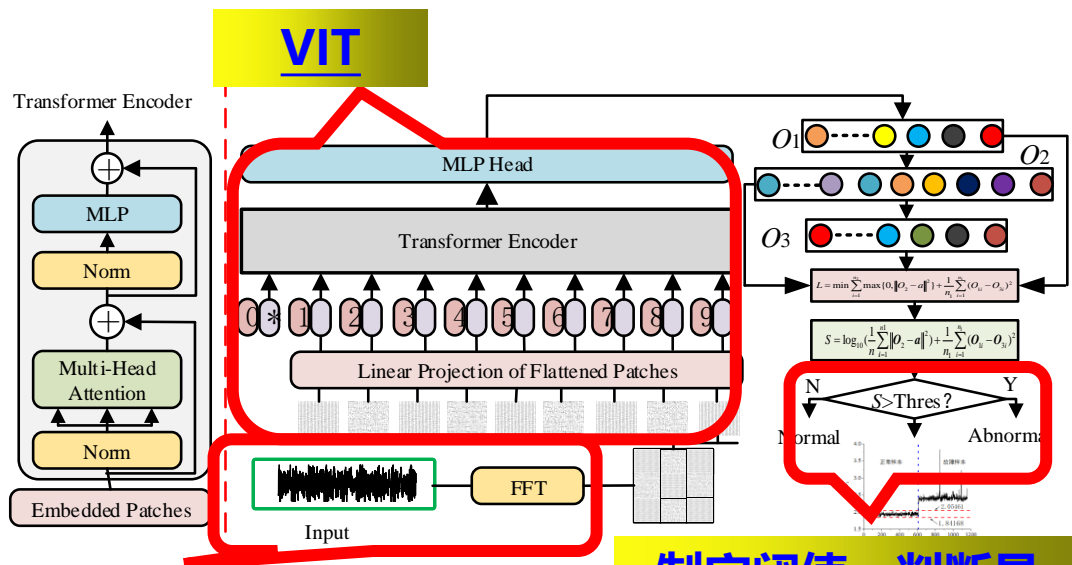
不是故障特征频率



结论:

正常和故障状态, 在小波第四层分解信号的包络谱中均出现了明显的 **18.5Hz** 的频率, 该频率与理论计算所得的外圈故障特征频率 **17.98Hz** 非常接近。分析认为, 该特征频率实则为滚动轴承固有的 **VC 频率**, 并非真正意义下的故障特征频率。低转速条件下轴承 **VC 振动频率** 与外圈故障频率基本相同, 这会导致无法通过搜索特征频率的诊断方法区分出外圈频率和 **VC 频率**。

提出了基于深度异常检测方法的滚动轴承低转速状态下故障的识别



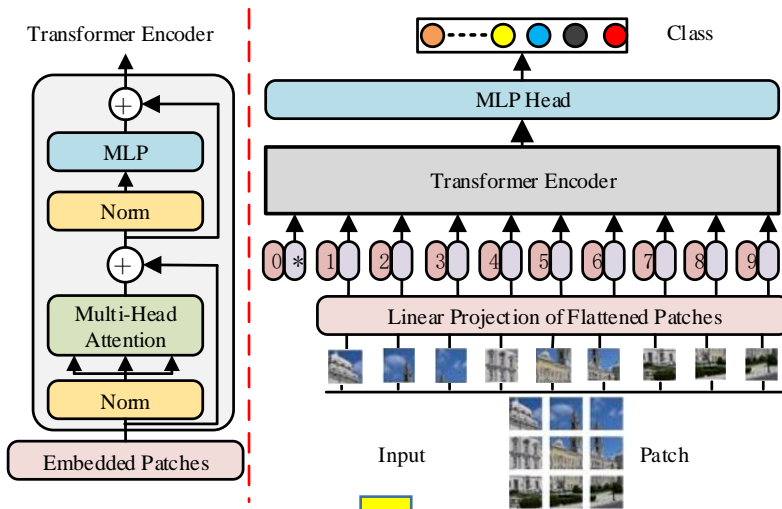
输入

制定阈值, 判断是否异常

ViT-DSVDD模型框架

计算流程

- ◆ 1) 对单个1s样本数据进行FFT, 获得其频谱数据, 并转换为二维矩阵, 作为模型的输入。仅利用正常状态的样本完成ViT-DSVDD模型的训练, 并制定阈值。
- ◆ 2) 保存训练完成的模型参数。
- ◆ 3) 在测试过程中, 将不同状态下的测试样本经过预处理后输入训练完成的模型, 通过所制定的阈值判断当前输入是否异常。



$$\text{Attention}(Q, K, V) = \text{soft max} \left(\frac{QK^T}{\sqrt{d_k}} \right) V$$


VIT

损失函数


◆对于ViT-DSVDD模型，其目标损失函数主要有两部分组成。一是由自编码器结构的输出 O_2 所构建的超球体，该超球体能够准确描述正常类的边界。二是具有相同维度 n_1 的两个输出 O_1 和 O_3 ，二者应具有较高的相似度

$$L = \min \sum_{i=1}^{n_2} \max \{0, \|O_2 - a\|^2\} + \frac{1}{n_1} \sum_{i=1}^{n_1} (O_{1i} - O_{3i})^2$$


(1) 不同数据预处理方法对检测结果的影响



方法1: 原始数据转换为二维矩阵




方法3: 小波尺度谱图



方法2: FFT后转换为二维就矩阵

不同
预处理方法
的检测
结果对比




结论: 在3种预处理方法的前提下, 检测精度均能达到92.00%以上。其中采用数据数据预处理方法2, 能够获得更好的检测效果。


(2) 不同异常检测方法对比及泛化性能

转速	ViT-DSVDD	DSVDD	OC-NN	DCAE
摇转	99.37	64.28	31.24	52.81
120rpm	100.00	96.87	94.79	91.38

摇转检测结果



在第二、三、四次低转速滚动轴承试验上进行了验证。选用训练完成的ViT-DSVDD模型以及所制定的阈值进行泛化性能验证。



摇转结果

定转速结果

结论：在120rpm时，检测精度均能达到91.00%以上。然而，在摇转状态下ViT-DSVDD相比其余几种方法具有巨大的优势，其检测精度可达到99.37%，而其余三种方法最高仅为64.28%。

结论：对于不同测试时间内摇转和定转速的检测精度均达到了93.52%以上。其中摇转的检测精度为93.52%，而定转速的检测精度可达97.38%。

某型航空发动机主轴承低转速试验验证

第四章

在某型涡扇航空发动机上进行了低转速主轴承剥落故障模拟试验。试验中在三、四支点的滚动轴承上预置了不同的复合故障。采样频率为16000Hz，传感器安装测点为中介机匣垂直振动测点，转速为120rpm,160rpm。


转速	样本数量		
	正常	故障	样本总量
120rpm	160	648	808
160rpm	160	766	926




四支点滚动体、外圈和内圈预置故障情况



三支点内圈、外圈和球预置故障情况



120rpm的检测结果



160rpm的检测结果

结论：当转速为120rpm时，可以设置阈值为0.08，即可完全将正常和故障状态进行区分，此时，检测精度可达到100.00%。

当转速为160rpm时，计算所得的阈值为0.10，检测精度同样达到了100.00%。

◆ 采用传统的信号分析方法很难或无法直接获得低转速状态下滚动轴承轴承的故障特征频率，即无法采用寻找特征频率的方法实现低转速滚动轴承的故障诊断。

◆ 建立了ViT-DSVDD的深度异常检测方法

无论是摇转还是恒定转速，可仅仅依靠正常状态的样本完成模型的训练，通过按 3σ 设置合理的阈值，即可实现对输入数据的异常检测。在真实的低转速航空发动机滚动轴承故障诊断中也同样验证了本文所提方法的有效性。

◆ 不同的数据预处理方法所获得的故障检测效果也不尽相同，其中FFT预处理法效果最好。

目录

1

绪论

2

无故障样本的滚动轴承故障异常检测

3

含少量故障样本的滚动轴承故障诊断

4

低速转动状态下滚动轴承故障异常检测

5

基于振动和油液的滚动轴承故障智能融合诊断

6

总结与展望

基于振动和油液的滚动轴承故障智能融合诊断

第五章

研究目的：从多源信息融合的角度出发，利用所获得的振动加速信息和滑油在线监测信息，采用基于多元高斯分布的融合诊断和模糊融合诊断两种方法，实现滚动轴承故障的融合诊断。提高整个航空发动机主轴承监控系统的准确性、有效性和可靠性。



高频振动信号



油液监测信号



数据采集

特征提取及多元高斯分布融合诊断方法



$$f(X|\mu, \Sigma) = \frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma|^{\frac{1}{2}}} \exp\left(-\frac{(X-\mu)^T \Sigma^{-1} (X-\mu)}{2}\right)$$


$$g(X|\mu, \Sigma) = \frac{(X-\mu)^T \Sigma^{-1} (X-\mu) - \frac{\beta}{2} \ln(2\sigma) - \frac{1}{2} \ln|\Sigma|}{2}$$

方法植入



机载健康诊断系统

方法植入



特征提取及模糊融合诊断方法



轴承故障告警



振动信号

油液信号

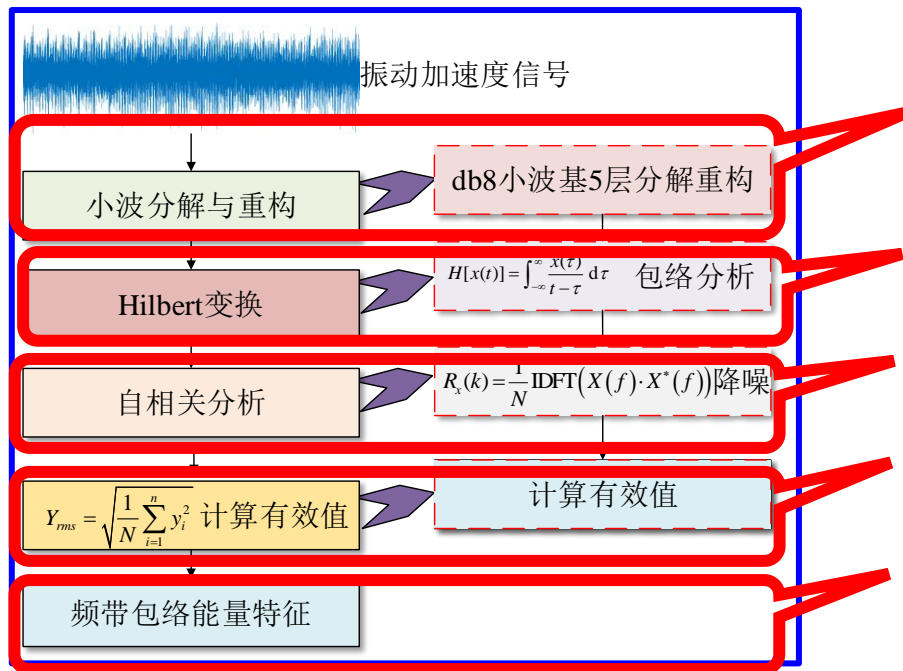
特征提取

融合诊断

诊断结果

计算流程

关键技术一：基于小波分解的振动加速度信号特征提取



频带包络能量特征的计算方法流程

db8小波基进行5层分解与重构


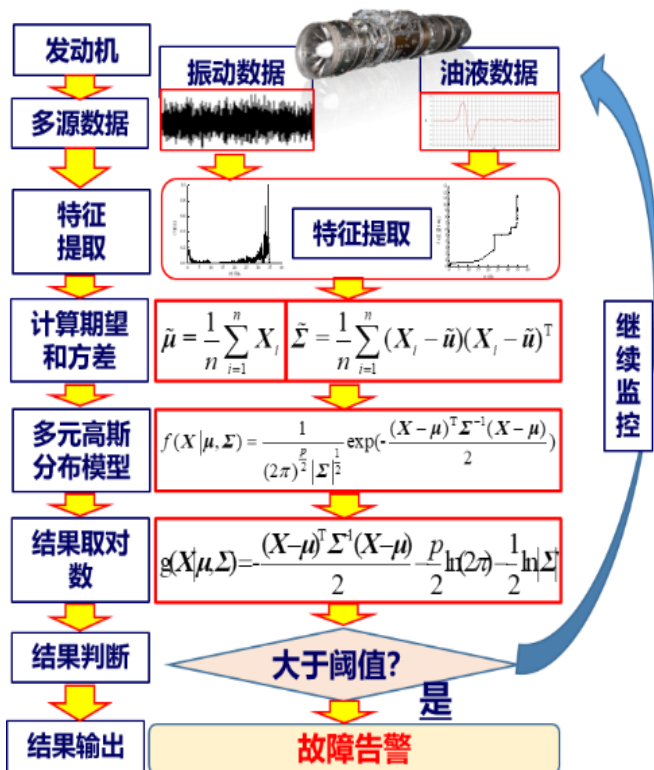
包络分析，得到6个包络信号

归一化自相关降噪VIT

计算有效值

频带包络能量特征

关键技术二：基于多元高斯分布的滚动轴承特征融合



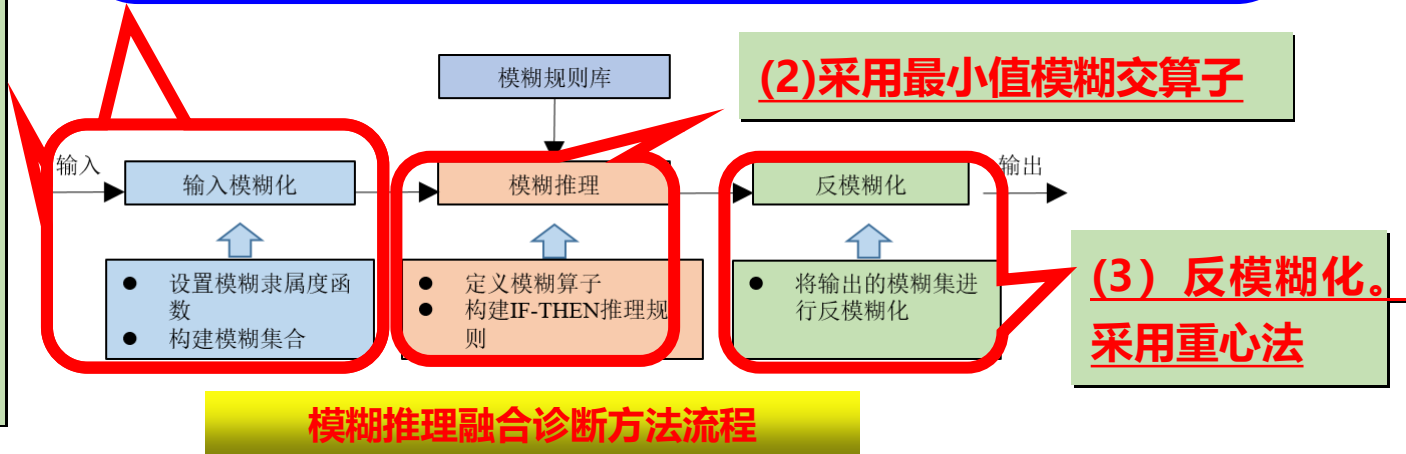
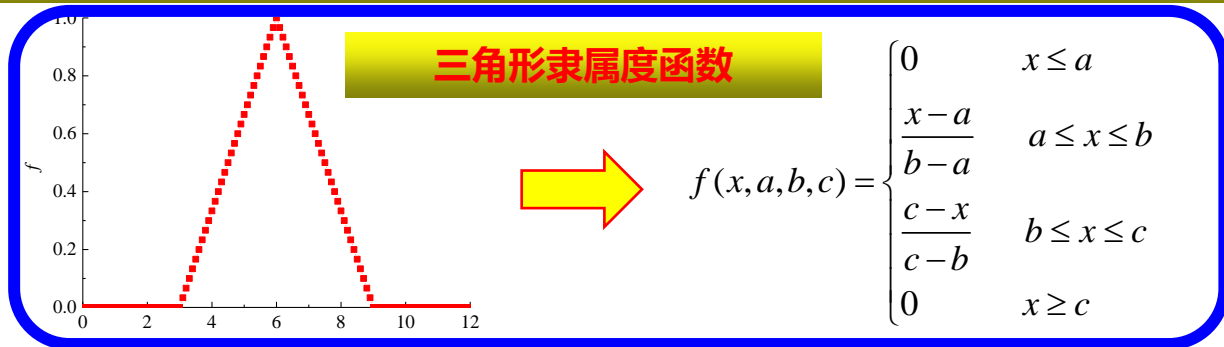
计算流程

- ◆ 选择正常状态下的;
- ◆ 仅利用正常样本的振动和滑油数据特征, 计算正常样本下的期望 μ 、协方差方差矩阵 建立多元高斯分布模型
- ◆ 将发动机实时监测的振动数据和滑油特征量作为输入, 计算 输出值, 并和阈值 作比较, 输出融合诊断结果。

关键技术三：振动和油液数据的模糊融合诊断

(1) 输入输出数据的模糊化处理。


输入变量，定义三个模糊论域，分别代表小、中、大三种不同程度的振动量级磨损程度。对于输出量，定义“正常”、“告警”、“异常”三种模糊语义集合



- (1) 如果频带包络值小, 并且有效值小, 并且磨屑少, 则诊断结果为正常, 权重1.0;
- (2) 如果频带包络值小, 并且有效值小, 并且磨屑中, 则诊断结果为正常, 权重0.7;
- (3) 如果频带包络值小, 并且有效值小, 并且磨屑多, 则诊断结果为告警, 权重0.6;
- (4) 如果频带包络值小, 并且有效值中, 并且磨屑少, 则诊断结果为告警, 权重0.6;
- (5) 如果频带包络值小, 并且有效值中, 并且磨屑中, 则诊断结果为告警, 权重0.8;
- (6) 如果频带包络值小, 并且有效值中, 并且磨屑多, 则诊断结果为告警, 权重0.8;
- (7) 如果频带包络值小, 并且有效值大, 并且磨屑少, 则诊断结果为告警, 权重0.6;
- (8) 如果频带包络值小, 并且有效值大, 并且磨屑中, 则诊断结果为告警, 权重1.0;
- (9) 如果频带包络值小, 并且有效值大, 并且磨屑多, 则诊断结果为异常, 权重0.9;
- (10) 如果频带包络值中, 并且有效值小, 并且磨屑少, 则诊断结果为正常, 权重0.8;
- (11) 如果频带包络值中, 并且有效值小, 并且磨屑中, 则诊断结果为告警, 权重0.8;
- (12) 如果频带包络值中, 并且有效值小, 并且磨屑多, 则诊断结果为异常, 权重0.8;
- (13) 如果频带包络值中, 并且有效值中, 并且磨屑少, 则诊断结果为告警, 权重0.8;
- (14) 如果频带包络值中, 并且有效值中, 并且磨屑中, 则诊断结果为告警, 权重1.0;
- (15) 如果频带包络值中, 并且有效值中, 并且磨屑多, 则诊断结果为异常, 权重1.0;
- (16) 如果频带包络值中, 并且有效值大, 并且磨屑少, 则诊断结果为告警, 权重0.8;
- (17) 如果频带包络值中, 并且有效值大, 并且磨屑中, 则诊断结果为异常, 权重0.8;
- (18) 如果频带包络值中, 并且有效值大, 并且磨屑多, 则诊断结果为异常, 权重1.0;
- (19) 如果频带包络值大, 并且有效值小, 并且磨屑少, 则诊断结果为正常, 权重0.8;
- (20) 如果频带包络值大, 并且有效值小, 并且磨屑中, 则诊断结果为告警, 权重0.8;
- (21) 如果频带包络值大, 并且有效值小, 并且磨屑多, 则诊断结果为异常, 权重0.8;
- (22) 如果频带包络值大, 并且有效值中, 并且磨屑少, 则诊断结果为告警, 权重0.6;
- (23) 如果频带包络值大, 并且有效值中, 并且磨屑中, 则诊断结果为告警, 权重0.8;
- (24) 如果频带包络值大, 并且有效值中, 并且磨屑多, 则诊断结果为异常, 权重1.0;
- (25) 如果频带包络值大, 并且有效值大, 并且磨屑少, 则诊断结果为异常, 权重0.6;
- (26) 如果频带包络值大, 并且有效值大, 并且磨屑中, 则诊断结果为异常, 权重0.8;
- (27) 如果频带包络值大, 并且有效值大, 并且磨屑多, 则诊断结果为异常, 权重1.0;

基于滚动轴承加速疲劳试验器的振动和油液数据的融合诊断验证

试验概况: 2017年4月6日和2018年5月9日,在滚动轴承**疲劳试验机**上和配套的**振动信号采集系统**以及相关的**油液磨屑在线监测系统**进行了滚动轴承全寿命加速疲劳试验.轴承型号为6206深沟球轴承, 转速为11500rpm, 采样频率为32kHz, 存储间隔时长为0.1小时。最终因4号滚动轴承发生**内圈、滚珠、保持架**复合故障而停止。共获得**445组**振动加速度样本数据。试验进行**15小时**时, **Fe元素**质量开始增加, 最终**Fe元素**质量为**11.52mg**。









轴承内圈剥落故障



轴承滚珠剥落故障

部分特征数据





基于多元高斯分布的融合诊断结果

第五章

均值	特征	FBEE1	FBEE2	FBEE3	FBEE4	FBEE5	FBEE6	有效值	峭度	Fe质量
	均值	0.027	0.1022	0.0402	0.0048	0.0045	0.0098	0.0206	0.6700	0.5655


协方差矩阵	特征	FBEE1	FBEE2	FBEE3	FBEE4	FBEE5	FBEE6	有效值	峭度	Fe质量
	FBEE1	0.0016	0.0051	0.0017	0.0001	0.0001	0.0006	0.0013	0.00140	0.0032
	FBEE2	0.0051	0.0170	0.0052	0.0003	0.0003	0.002	0.0043	0.0045	0.0094
	FBEE3	0.0017	0.0052	0.0020	0.0001	0.0001	0.0006	0.0014	0.00110	0.00350
	FBEE4	0.0001	0.0003	0.0001	0	0	0	0.0001	0	0.0001
	FBEE5	0.0001	0.0003	0.0001	0	0	0	0.0001	0.0001	-0.0001
	FBEE6	0.0006	0.002	0.0006	0	0	0.0002	0.0005	-0.0006	-0.0012
	有效值	0.0013	0.0043	0.0014	0.0001	0.0001	0.0005	0.0011	-0.0015	-0.0026
	峭度	-0.0014	-0.0045	-0.0011	0	0.0001	-0.0006	-0.0015	0.0165	0.0028
Fe质量	0.0032	0.0094	0.0035	0.000100	0.0001	0.0012	0.0026	0.0028	0.0112	




结论：经过融合诊断后。所得的结果在正常阶段和故障阶段具有较为明显的差异，在0-15.2小时为正常阶段，15.2-20.6小时为告警阶段，20.6小时后为故障阶段。同时，从归一化的结果可以看出，当指定阈值为0.1时，可判断当前输入是否异常。

- 1) 与有效值的对比：**有效值故障时间21小时，融合诊断故障时间15.2小时，**提前约6小时。**
 - 2) 与峭度值的对比：**峭度值故障时间20小时，融合诊断故障时间15.2小时，**提前约6小时。**
 - 3) 与频带包络能量特征的对比：**故障时间20小时，融合诊断故障时间15.2小时，**提前约6小时。**
 - 4) 与滑油特征的对比：**故障时间30小时，融合诊断故障时间15.2小时，**提前约15小时。**
- 相对而言，融合诊断结果更加可靠。**

融合诊断结果 (未归一化)



融合诊断结果 (归一化)



结论:(1)该次试验在约**15.4**小时开始出现异常, 在**15.4-23.7**小时之间为告警阶段, 之后融合诊断结果开始突增 (大于0.5) 视为故障阶段。
(2)模糊融合诊断方法在**15.4**小时实现告警, 而相比单一方法, 这一时间至少提前了约5小时左右。从融合结果来看, 融合后的特征量更加平稳, 相比单一的特征更容易进行告警界限值的制定。

时间	高斯多元分布	模糊融合诊断	误差
告警	15.2	15.2	<u>0.2</u>
故障	20.6	23.7	<u>3</u>

与高斯多元分布的对比: 1) 从计算精度和效率来看: (1) 多元高斯分布方法主要是以正常阶段的数据样本为输入, 完全依靠分析数据完成模型的训练和诊断。具有模型简单, 计算效率高的特点。(2) 模糊融合诊断方法通过制定合适的规则完成融合诊断, 能够融合专家的诊断经验计算结果更为可靠。

2) 从实际应用情况分析:

多元高斯分布模型适合没有故障案例的情况下的诊断, 属于异常诊断的一部分。仅利用正常样本即可完成轴承运行状态是识别, 其诊断结果依赖于数据及其特征提取的正确性。而模糊融合诊断方法主要依赖专家的诊断知识规则, 具有更好的适应性。

基于航空发动机主轴承故障演化的振动和油液数据融合诊断


试验概况：采用某型航空发动机进行中介轴承外圈剥落故障至失效的整机试验，本次试验共进行约20小时。当机载振动值达到40mm/s时，为确定故障提前预警时间余量，单次试验循环26分钟，大发动机最大状态工作时间为1分钟。当机载振动值 $>65\text{mm/s}$ 时，试验停止。




油液传感器



航空发动机油液传感器安装位置



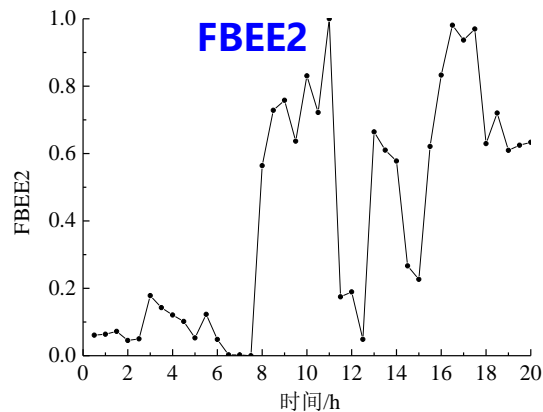






Fe元素质量




Fe元素质量增加量

部分特征数据





高斯多元分布融合诊断结果



模糊融合诊断结果

结论：(1) 多元高斯分布融合方法所诊断的结果为：0-5小时之间为正常，而模糊融合诊断方法判断的正常阶段为0-7.5小时之间，相比而言晚了2.5小时实现告警。

(2) 在正常阶段，无论是多元高斯分布方法还是模糊融合诊断方法所得输出值均小于0.2，而在故障阶段两种方法的输出值保持在1左右。从融合结果来看，两种方法保持了高度的一致性，互相进行验证，也进一步说明了本文所提的两种融合诊断方法的有效性和实用性。

(3) 因为振动特征量能够实现中介轴承的大提前量告警，因此在融合中期主导作用，融合后的特征量相比单一的特征量更加平稳，更加容易进行告警界限值的制定。

- ◆ 提出两种滚动轴承故障融合诊断方法，将振动信号和滑油信号监测结果相融合，提高了监测结果的可靠性；
- ◆ 对原始振动加速度信号进行频带分解后所计算的频带包络能量特征值，能够表征滚动轴承故障出现至失效的早期演化过程；
- ◆ 在主轴承故障演化至失效的晚期，滑油碎屑在线监测会表现出了明显的上升趋势，利用振动和油样数据对滚动轴承早、晚期演化过程进行融合诊断，通过将二者的融合大大提高了航空发动机主轴承故障的准确率。

目录

1

绪论

2

无故障样本的滚动轴承故障异常检测

3

含少量故障样本的滚动轴承故障诊断

4

低速转动状态下滚动轴承故障异常检测

5

基于振动和油液的滚动轴承故障智能融合诊断

6

总结与展望

◆ 1) 建立了无故障样本下滚动轴承故障异常检测方法

针对滚动轴承故障数据难以获取的难题，提出了融合深度强化学习的双输入异常检测方法。所提的方法利用正常类样本完成模型的训练。在检测时，正常类样本的输出结果往往趋近于0或某一范围，且较平稳，而故障类样本的输出往往较大，和正常类样本的输出具有明显的差异。通过这种差异，可以很明显的区分正常和异常状态。以上结论在多种数据集上均得到了验证。

◆ 2) 针对含少量故障样本的情况建立了多种滚动轴承故障诊断方法

(1) 提出了一种基于强化学习的不平衡样本数据故障诊断方法，该方法的核心思想是采用两个网络分别实现滚动轴承的多数类和少数类样本的分类。(2) 改进了深度残差网络，改进后网络在训练效率，诊断精度上均有很大的提升。(3) 提出了一种多任务的深度残差网络用于滚动轴承的故障告警、故障诊断与损伤大小预测任务。上述三种模型在滚动轴承试验台数据集和某型真实的航空发动机滚动轴承故障数据集上均得到了有效性验证。

◆ 3) 提出了低转速状态下基于深度学习的滚动轴承异常检测方法

由于很难采用信号分析寻找特征频率的方法实现低转速状态下滚动轴承的故障检测。提出了采用异常检测方法实现低转速滚动轴承故障异常检测的新思路。研究发现，采用基于TransFormer的异常检测方法均能很好的实现低转速状态下滚动轴承的异常检测，分析认为，这种方法能够提取相距较远的两个数据点之间的关联特征，而这种特征恰好与低转速状态下滚动轴承振动加速度信号具有冲击间隔时间长的特点相一致。研究结果表明，所提的方法无论是实际发动机中还是试验器数据上均取得了较好的应用效果。

◆ 4) 提出了基于振动和油液数据的滚动轴承故障融合诊断方法

从多源信息融合的角度出发，利用所获得的振动加速信息和滑油在线监测信息，采用基于多元高斯分布的融合诊断和模糊融合诊断两种方法，实现滚动轴承故障的融合诊断。在试验器数据集和实际某型航空发动机滚动轴承数据集上对所提的两种融合诊断方法进行了有效性验证，说明了本文方法的有效性。

◆ 1) 进一步在不同型号的航空发动机主轴承上进行验证

本文所提的无故障样本下的异常检测方法，对于同一型号的滚动轴承需要一定数量的正常类样本才能完成模型的训练，但是，对于不同型号的滚动轴承而言，该方法并不能很好的进行检测。因此，后续需要在该方法的框架之上，研究更为先进的迁移学习方法，进而实现更高的异常检测精度。同时，异常检测方法和滚动轴承故障动力学相结合的方法，也是未来仍需研究的内容之一。

◆ 2) 进一步采用迁移学习实现少故障样本下的诊断

对于少量样本下滚动轴承故障诊断问题，后续研究中可结合生成对抗学习、迁移学习、对比学习等内容实现更高精度的诊断。

◆ 3) 进一步研究低转速状态下航空发动机滚动轴承的故障诊断方法，包括信号分析和深度学习方法

对于低转速状态下航空发动机而言，一方面是采用更为先进的信号分析方法进一步验证本文所得的结论。另一方面是研究速度更快、检测精度更高的轻量化深度异常检测方法。

◆ 4) 考虑研究更为先进的深度学习特征提取方法实现融合诊断

本文所提的融合诊断方法仅考虑的传统特征，并进行了有效性验证。未来可以考虑研究更为先进的深度学习特征提取方法，以及基于深度学习的多源信号融合诊断方法，以进一步提高融合诊断精度。同时，需要进一步加强工程实际应用研究。

◆ 5) 进一步的进行实际工程应用验证

提出的各种方法在某型航空发动机滚动轴承数据集上进行了验证，对于工程实际有一定的参考价值和意义。在后续研究中，可以将其应用至其余各种型号的航空发动机主轴承的故障诊断中，以进行更充分的验证，为真正应用于工程实际奠定基础。

- [1] **Kang yuxiang**, Chen Guo,Wang Hao, Pan Wenping, Wei Xunkai.Fault anomaly detection method of aero-engine rolling bearing based on distillation learning.[J]. ISA Transactions(录用)(SCI , Q1, IF=7.3, Top期刊).
- [2] **Kang yuxiang**, Chen Guo,Wang Hao, Pan Wenping, Wei Xunkai.Dual-Input Anomaly Detection Method Based on Deep Reinforcement Learning[J].Structural Health Monitoring.2023;0(0). doi:10.1177/14759217231188002 (SCI , Q1, IF=7.5).
- [3] **Kang yuxiang**, Chen Guo,Wang Hao, Wei Xunkai. A New Dual-Input Deep Anomaly Detection Method for Early Faults Warning of Rolling Bearings [J].Sensors.(录用) (SCI , Q2, IF=3.9).
- [4] **Yuxiang Kang**;Guo Chen;Wenping Pan;Xunkai Wei;Hao Wang;Zhiyuan He.A dual-experience pool deep reinforcement learning method and its application in fault diagnosis of rolling bearing with unbalanced data[J].Journal of Mechanical Science and Technology.2023,Vol.37(No.6): 2715-2726.(SCI, Q4, IF=1.8) .
- [5] **Yuxiang Kang**;Guo Chen;Wenping Pan;Xunkai Wei;Hao Wang; A Deep Anomaly Detection with Same Probability Distribution and Its Application in Rolling Bearing[J]. Journal of Dynamic Systems, Measurement and Control. (录用)(SCI Q4, IF=1.8).
- [6] **康玉祥**,陈果,尉询楷等.深度残差对冲网络及其在滚动轴承故障诊断中的应用[J].航空学报,2022,43(08):63-74. (EI,T1期刊)
- [7] **康玉祥**,陈果,尉询楷等.基于残差网络的航空发动机滚动轴承故障多任务诊断方法[J].振动与冲击,2022,41(16):285-293.DOI:10.13465/j.cnki.jvs.2022.16.037. (EI)
- [8] **康玉祥**,陈果;盛嘉玖;王浩;尉询楷.低转速航空发动机滚动轴承故障深度异常检测方法[J].振动与冲击(录用). (EI)
- [9] **康玉祥**,陈果;王浩;尉询楷.基于自监督深度一类分类的滚动轴承早期故障预警[J].航空动力学报(录用). (EI)
- [10] **Kang yuxiang**, Chen Guo,Wang Hao, Pan Wenping, Wei Xunkai.Knowledge distillation anomaly detection method based on enhanced Transformer under sensitive feature constraint and its application[J].Expert Systems With Applications(投稿中)(SCI , Q1, IF=8.5, Top期刊)
- [11] **Yuxiang Kang**;Guo Chen;Jiajiu Sheng.et.al.Deep Anomaly Detection Method for Rolling Bearings on Low- Speed Based with Large-Scale Convolution Kernel[J].Journal of Mechanical Science and Technology.(小修)(SCI, Q4, IF=1.8) .

- 1.国家科技重大专项 (2017IV00080045) : 典型故障动力学建模和诊断方法研究.2019-2020;
- 2.国家科技重大专项子专题 (J2019-IV-0004-0071) : 复杂服役环境下主轴承典型故障宏观动力学研究, 2020.01-2023.12, 主要参与人员;
- 3.国家自然科学基金项目 (51675263) : 基于监测数据和损伤力学的复杂工况下滚动轴承故障预测研究. 2019-2020;
- 4.国家自然科学基金面上项目 (52272463) : 基于深度异常检测和元学习的航空发动机主轴承早期故障预警与演化诊断, 2023.01-2026.12, 主要参与人员;
- 5.中国航发沈阳发动机研究所项目: 振动双稳态问题动力学机理试验与仿真技术研究, 2023.6-2024.6, 主要参与人员;
- 6.中国航发商用发动机有限责任公司项目: 民用航空发动机滑油摩擦磨损颗粒测试分析技术研究, 2020.1-2021.12。

致谢

致·谢·

博士四年，新冠疫情三年，这些年祖国为抗击疫情，保障我们的生活付出了巨大代价。同时，在当今这个动荡的国际社会中，祖国给我们提供了安居乐业的生活、学习环境，为我们劈开了各种荆棘，才有了此刻的花好月圆。感谢祖国，我想今后一定要用更加饱满的热情去感恩她，热爱她。感谢伟大的祖国。☺

九月的南京丹桂飘香，在这个喜迎丰收的时节，我要衷心的感谢这一路走来给予我帮助各位老师、同学及朋友。☺

衷心感谢我的导师陈果教授。陈老师严谨、务实、积极的学习态度深深的影响、鞭策着我。陈老师的教导就像夜空中的一盏明灯，始终激励我勇往直前。犹记得陈老师手把手教我们调试 C++ 程序的场景；犹记得陈老师曾在早上 6:00 为我们修改论文的背影。四年时间，老师曾无微不至的关怀，无论是从平日的学习还是从本文选题到成文，为了我的成长和未来的有所为，老师均倾注了大量的心血。老师的谆谆教诲，如春风化雨般滋润着我的心田，也是我今后前进的阶梯。感谢陈老师四年来的包容和耐心，能成为您的学生我真的感到很荣幸，谢谢！☺

四年间，有幸认识了北京空军研究院航空兵研究所的尉诤楷高工、王浩工程师，您曾帮助我迈过了许多学术坎，感谢您们；有幸认识了南京航空航天大学戴朝平教授、罗贵火教授、陈茉莉老师和潘文平老师，感谢您们在学术和科研上对我指引；有幸认识了中国航发沈阳发动机研究所的乔保栋高工、秦天龙高工、何俊杰高工、高强高工等，感谢您们在我学习、科研路上提供的帮助；有幸认识了哈尔滨轴承集团于庆杰高工和刁庆高工，感谢您们在科研项目上对我的指导；有幸认识了哈尔滨工业大学的张传伟教授和西安交通大学曹宏瑞教授以及曹教授的学生马天宇博士，感谢您们在科研项目上的指导、帮助，您们也是我科研路上的榜样。☺

衷心感谢我的硕士导师沈阳航空航天大学姜春英副教授这些年对我的关心、开导与帮助，是您推荐我成为了陈老师的弟子，您是我科研路上的第一位引路人，我也将铭记您的教导，踏实做人、努力做事。感谢我的高中老师古浪县第三中学的王明年老师和王生才老师，感谢您们在我求学路上的帮助与鼓励，也祝愿两位老师身体健康、万事如意。☺

感谢智能诊断与专家系统研究室的同门金根博士、刘西洋博士、张旭博士、沈响响博士、赵紫豪博士、何超博士，硕士师弟钱进、盛嘉玖、刘曜宾、刘富海、陈智超，以及已毕业的郝腾飞博士、李爱博士、王海飞博士、贺志远博士，硕士师弟杨默晗、张杰毅、李伦绪、赵旭升，师妹马佳丽、王雨薇等人在学习和生活上给予我的帮助，感谢同窗鲁其兴博士、林大地博士在博士期间对我的帮助与鼓励，同窗情谊，一生铭记，祝愿各位在今后的生活、工作和学习中一切顺利。☺

感谢我的家人。这些年，家人总是默默的付出、支持与陪伴，他们是我求学路上坚强的后盾，今后我要好好照顾家人，孝顺父母，祝我的家人身体健康，平平安安。感谢我美丽的妻子裴婷婷女士。求学期间是你承担起了家中大小繁杂的事务，能够让我安心的学习。今后，我要给予你更加热烈的爱，共同营造我们幸福的小家。也希望我们今后能携手与共，去创造属于我们的、红红火火的日子。☺

衷心感谢评审论文和出席答辩的各位专家、教授于百忙之中给予悉心的指导与帮助。☺最后，再一次感谢曾经给予我帮助的老师、同学、朋友们，再次祝愿各位身体健康，事事顺意。☺

康玉祥·

2023年9月25日·

导师：陈果教授（南京航空航天大学）

北京航空兵研究所：尉诤楷高工、王浩工程师；

南京航空航天大学：戴朝平教授、罗贵火教授、陈茉莉和潘文平老师；

沈阳发动机研究所：乔保栋高工、秦天龙高工、何俊杰高工、高强高工等；

哈尔滨轴承集团：于庆杰高工和刁庆高工；

哈尔滨工业大学：张传伟教授；

西安交通大学：曹宏瑞教授、马天宇博士；

沈阳航空航天大学：姜春英副教授；

古浪县第三中学：王明年老师和王生才老师；

同门：金根博士、刘西洋博士、张旭博士、沈响响博士、赵紫豪博士、

何超博士，硕士师弟钱进、盛嘉玖、刘曜宾、刘富海、陈智超，以及

已毕业的郝腾飞博士、李爱博士、王海飞博士、贺志远博士，硕士师

弟杨默晗、张杰毅、李伦绪、赵旭升，师妹马佳丽、王雨薇等人；

同窗：鲁其兴博士、林大地博士；

感谢我的家人

评审论文和出席答辩的各位专家、教授

感谢伟大的祖国给我们和平的生活、学习环境。

谢谢各位专家及同学!
敬请批评指正